

UNIVERSIDAD CARLOS III DE MADRID

ESCUELA POLITÉCNICA SUPERIOR

DEPARTAMENTO DE INGENIERÍA MECÁNICA



**MODELO INVERSO DE AMORTIGUADOR MAGNETO-
REOLÓGICO BASADO EN REDES NEURONALES.**

TRABAJO FIN DE GRADO

GRADO EN INGENIERÍA MECÁNICA

AÑO DE PRESENTACIÓN: 2013

AUTOR: AGUSTÍN GÓMEZ FERNÁNDEZ

DIRECTORA: DRA. MARÍA JESÚS LÓPEZ BOADA

ÍNDICE

CAPÍTULO 1:INTRODUCCIÓN.....	1
1.1 OBJETIVO.....	2
2.1 ESTRUCTURA DEL PROYECTO.....	3
CAPÍTULO 2:COMPONENTES DE UNA SUSPENSIÓN VEHICULAR.....	4
2.1 INTRODUCCIÓN.....	4
2.2 ELEMENTOS ELÁSTICOS DE UNA SUSPENSIÓN.....	4
2.2.1 BALLESTAS.....	4
2.2.2 MUELLES HELICOIDALES.....	6
2.2.3 BARRAS DE TORSIÓN.....	7
2.3 BARRA ESTABILIZADORA.....	8
2.4 COJINETES ELÁSTICOS Y SILENTBLOCKS.....	9
2.5 MANGUETA.....	10
2.6 RÓTULAS.....	10
2.7 TRAPECIOS.....	11
2.8 AMORTIGUADORES.....	11
2.8.1 AMORTIGUADORES HIDRÁULICOS CONVENCIONALES.....	12
2.8.2 AMORTIGUADORES PRESURIZADOS.....	14
2.8.3 AMORTIGUADORES CON GAS.....	15
CAPÍTULO 3: TIPOS DE SUSPENSIÓN: ACTIVA, PASIVA,SEMI-ACTIVA.....	16
3.1 INTRODUCCIÓN.....	16
3.2 SUSPENSIÓN PASIVA.....	16
3.3 SUSPENSIÓN ACTIVA.....	17
3.3.1 HIGH BANDWIDHT.....	18
3.3.2 LOW BANDWIDHT.....	19
3.4 SUSPENSIÓN SEMI-ACTIA.....	19
3.4.1 SUSPENSIÓN SEMI-ACTIVA CON AMORTIGUADOR MR.....	21
CAPÍTULO 4: FLUIDOS MAGNETO-REOLÓGICOS.....	23
4.1 INTRODUCCIÓN.....	23
4.2 COMPORTAMIENTO DE UN FLUIDO MAGNETO-REOLÓGICO ANTE UN CAMPO MAGNÉTICO.....	23
4.3 PROPIEDADES MAGNÉTICAS.....	25

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

4.4	PROPIEDADES REOLÓGICAS.....	25
4.5	APLICACIONES DE FLUIDOS MAGNETO-REOLÓGICOS.....	26
4.5.1	AUTOMOTRZ.....	26
4.5.2	ROBÓTICA.....	27
4.5.3	CONTROL DE VIBRACIÓN SÍSMICA EN ESTRUCTURAS.....	27
4.5.4	APLICACIÓN DE UN AMORTIGUADOR MR A LA SUSPENSIÓN DE UN AUTOMOVIL.....	28
CAPÍTULO 5 :MODELOS DIRECTOS PARAMÉTRICOS DE AMORTIGUADOR MR.....		29
5.1	INTRODUCCIÓN.....	29
5.2	MEDIDAS EXPERIMENTALES EN EL AMORTIGUADOR MR.....	30
5.3	MODELOS PARAMÉTRICOS PARA AMORTIGUADOR MR.....	31
5.3.1	MODELOS EVOLOTIVOS MEDIANTE ECUACIONES DIFERENCIALES.....	31
5.3.2	MODELOS ALGEBRAICOS.....	34
5.4	COMPARACIÓN DE LOS MODELOS PARAMÉTRICOS.....	36
CAPÍTULO 6: MODELO INVERSO NO PARAMÉTRICO DE AMORTIGUADOR MR.....		39
6.1	INTRODUCCIÓN.....	39
6.2	SIMULACIÓN DEL COMPORTAMIENTO DE UN AMORTIGUADOR MR.....	40
6.3	TÉCNICAS DE MODELIZACIÓN PARA AMORTIGUADOR MR.....	43
6.3.1	RED NEURONAL MLP.....	43
6.3.2	ÓPTIMA ARQUITECTURA DE RED NEURONAL.....	49
CPÍTULO 7:REDES NEURONALES ARTIFICIALES.....		50
7.1	INTRODUCCIÓN.....	50
7.2	PERCEPTRÓN MULTICAPA.....	50
7.3	FUNCIÓN DE ACTIVACIÓN.....	52
7.4	FUNCIÓN DE SALIDA.....	55
7.5	PESOS SINÁPTICOS.....	56
7.5.1	APRENDIZAJE SUEPERSIVADO.....	56
7.5.2	APRENDIZAJE NO SUPERVISADO.....	58
7.6	ASOCIACIÓN ENTRE LAS INFORMACIONES DE ENTRADA Y DE SALIDA.....	59
7.7	REPRESENTACIÓN DE LA INFORMACIÓN DE ENTRADA Y DE SALIDA.....	60
CAPÍTULO 8: ALGORITMO DE APRENDIZAJE "BACKPROPAGATION".....		61
8.1	INTRODUCCIÓN.....	61
8.2	REGLA DE APRENDIZAJE DEL ALGORITMO "BACKPROPAGATION".....	62

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

CAPÍTULO 9: DATOS EXPERIMENTALES EN ENTRENAMIENTO DE RED MLP.....	68
9.1 INTRODUCCIÓN.....	68
9.2 CONJUNTO DE PATRONES DE ENTRENAMIENTO Y VALIDACIÓN.....	69
9.3 ARQUITECTURA Y ENTRENAMIENTO DE LA RED NEURONAL.....	71
9.3.1 RED NEURONAL CON UNA CAPA OCULTA Y 20 NEURONAS EN CADA CAPA OCULTA.	71
9.3.2 RED NEURONAL CON DOS CAPAS OCULTAS Y 20 NEURONAS EN CADA CAPA OCULTA.....	75
9.3.3 RED NEURONAL CON TRES CAPAS OCULTAS Y 20 NEURONAS EN CADA CAPA OCULTA.....	80
9.3.4 RED NEURONAL CON TRES CAPAS OCULTAS Y 30 NEURONAS EN CADA CAPA OCULTA.....	88
9.4 VALIDACIÓN.....	95
CAPÍTULO 10: CONCLUSIONES Y TRABAJOS FUTUROS.....	99
BIBLIOGRAFÍA	100

ABSTRACT

The suspension of a vehicle plays an important role in both the stability and the comfort of the occupants. There are three types of suspension, the suspension first passive and active suspension semi-active suspension. Passive suspension is the simplest of all, to record such a shock absorber oil and typically a helical spring. The semi-active suspensions and active have a higher complexity but also better results. Active suspension include controlling the stability of each wheel independently, and consumes large power since it must be equipped with a large number of sensors that can detect variables produced during the movement of the vehicle, and actuators, which act accordingly to the sensed variables. This complex system of sensors and actuators price considerably expensive suspension therefore be handled another option, such as semi-active suspension.

One of the main research is to install magneto-rheological dampers in semi-active suspensions, such as amortiguadores respond, varying viscous stress to an applied magnetic field. The sensors detect a number of variables such as force applied to the damper, its speed, and frequency shift, so must be a current inside the damper that generates a magnetic field in response to the variables mentioned. There are different models which identify a relationship between force and current. On one side are the direct models, which attempt to find the relationship between the frequency, amplitude and current strength. Among the direct models, parametric models are based on differential or algebraic equations, and non-parametric models. On the other hand, are the inverse models, which relate the strength, frequency and amplitude with the flow that must be passed by the MR damper.

In this final degree work presents a magneto-rheological damper based on neural networks, because neural networks are an excellent resource for establishing a non-linear relationship between the strength, frequency and offset against the current. Proposed and studied various network topologies, in order to train these different patterns by training and validation.

Once trained to obtain the optimal network, it will be able to generate current in the damper to exert force indicating the driver.

AGRADECIMIENTOS

En el presente Trabajo de Fin de Grado, quiero agradecer en primer lugar a mi tutora María Jesús su ayuda y paciencia durante la realización del mismo.

En segundo lugar, a las dos personas más importantes de mi vida, a mi madre María Ángeles, y a mi padre Justino, ya que sin su apoyo no habría conseguido llegar hasta aquí, ya que muchas veces me han animado cuando pasaba por momentos no tan buenos y me han inculcado que nunca debo tirar la toalla y debo insistir hasta conseguir el objetivo, por muy difícil que sea este.

En tercer lugar al resto de mi familia, en especial a mis abuelos ya que estoy seguro que se sienten muy orgullosos de mí, a los cuales les guardo un profundo cariño.

Por último, no me quiero olvidar de mis amigos, que han aguantado lo pesado que me pongo hablando de mis estudios, y agradecerles los momentos inolvidables que hemos vivido y los que nos quedan por vivir.

ÍNDICE DE FIGURAS

Capítulo 2

FIGURA 2.1: BALLESTA.....	5
FIGURA 2.2: BALLESTA CON MONTAJE LONGITUDINAL.....	5
FIGURA 2.3: BALLESTA UBICADA POR DEBAJO DEL EJE.....	6
FIGURA 2.4: BALLESTA CON MONTAJE TRANSVERSAL.....	6
FIGURA 2.5: MUELLE HELICOIDAL.....	7
FIGURA 2.6: DOS MUELLES HELICOIDALES EN PARALELO.....	7
FIGURA 2.7: BARRAS DE TORSIÓN.....	8
FIGURA 2.8: FUNCIONAMIENTO BARRA ESTABILIZADORA.....	8
FIGURA 2.9: BARRA ESTABILIZADORA Y MUELLES DE SUSPENSIÓN.....	9
FIGURA 2.10: COJINETE ELÁSTICO EN BARRA ESTABILIZADORA.....	9
FIGURA 2.11: MANGUETA Y CONJUNTO MUELLE-AMORTIGUADOR.....	10
FIGURA 2.12: RÓTULA.....	10
FIGURA 2.13: TRAPÉCIOS DE SUSPENSIÓN.....	11
FIGURA 2.14: AMORTIGUADOR HIDRÁULICO BITUBO.....	13
FIGURA 2.15: AMORTIGUADOR HIDRÁULICO CONTROLADO POR VÁLVULAS.....	13
FIGURA 2.16: AMORTIGUADORES BITUBO PRESURIZADOS Y NO PRESURIZADOS.....	14
FIGURA 2.17: AMORTIGUADOR DE GAS.....	15

Capítulo 3

FIGURA 3.1: ESQUEMA SUSPENSIÓN PASIVA PARA UNA RUEDA.....	16
FIGURA 3.2: ESQUEMA DE SUSPENSIÓN ACTIVA.....	17
FIGURA 3.3: ESQUEMA DE UNA SUSPENSIÓN ACTIVA HIGH BANDWIDTH.....	18
FIGURA 3.4: ESQUEMA DE UN SISTEMA DE SUSPENSIÓN LOW BANDWIDTH.....	19
FIGURA 3.2: ESQUEMA SUSPENSIÓN SEMI-ACTIVA.....	20
FIGURA 3.3: ESQUEMA DE UN AMORTIGUADOR PILOTADO POR ELECTROVÁLVULAS.....	20
FIGURA 3.4: AMORTIGUADOR MR 1.....	22

Capítulo 4

FIGURA 4.1: EFECTO DE UN CAMPO MAGNÉTICO A UN FLUIDO MR.....	24
FIGURA 4.2: GRÁFICA ESFUERZO-DEFORMACIÓN.....	24
FIGURA 4.3: CURVA DE MAGNETIZACIÓN-CAMPO APLICADO.....	26
FIGURA 4.4: AMORTIGUADOR MR 2.....	26
FIGURA 4.5: ROBOT CON ARTICULACIONES CON FLUIDOS MR.....	27
FIGURA 4.6: PUENTE DEL LAGO DONG TING.....	27
FIGURA 4.7: AMORTIGUADOR MR PARA SEÍSMOS.....	28

Capítulo 5

FIGURA 5: AMORTIGUADOR MR 3.....	30
FIGURA 6: MODELO BOUC-WEN.....	31
FIGURA 5.3: MODELO BOUC-WEN MODIFICADO.....	32
FIGURA 5.4: MODELO DE DAHL MODIFICADO.....	34
FIGURA 5.5: MODELO ALGEBRAICO DE KWOK.....	34
FIGURA 5.6: CICLO DE HISTÉRESIS.VELOCIDAD FRENTE A LA FUERZA.....	35
FIGURA 5.7: ERRORES NORMALIZADOS PARA LOS DIFERENTES MODELOS.....	37

Capítulo 6

FIGURA 6.1. MODELO BOUC-WEN MODIDIFICADO 2.....	41
FIGURA 6.2: VALOR NUMÉRICO DE LAS CONSTANTES DEL MODELO PARAMÉTRICO.....	41
FIGURA 6.3: DESPLAZAMIENTO Y VOLTAJE APLICADO.FUERZA OBTENIDA EN EL AMORTIGUADOR.....	42
FIGURA 6.4: BUCLE FUERZA DESPLAZAMIENTO MODELO PARAMÉTRICO.....	42
FIGURA 6.5: FUERZA-VELOCIDAD MODELO PARAMÉTRICO.....	43
FIGURA 6.6: ARQUITECTURA RED NEURONLA MLP.....	43
FIGURA 6.7: RED NEURONAL COMPLETAMENTE CONECTADA.....	45
FIGURA 6.8: RED NEURONAL CON PESOS SUPERFLUOS ELIMINADOS.....	45
FIGURA 6.9: VOLTAJE OBTENIDO POR LA RED NEURONAL ÓPTIMA.....	46
FIGURA 6.10: PRIMER CONJUNTO DE SEÑALES DE VALIDACIÓN.....	47
FIGURA 6.11: SEGUNDO CONJUNTO DE SEÑALES PARA LA VALIDACIÓN.....	48
FIGURA 6.12: VOLTAJE PREDICHO POR LA RED PARA EL PRIMER CONJUNTO DE VALIDACIÓN..	48
FIGURA 6.13. VOLTAJE PREDICHO POR LA RED PARA EL SEGUNDO CONJUNTO DE VALIDACIÓN.....	49

Capítulo 7

FIGURA 7.1: ESTRUCTURA RED NEURONAL ARTIFICIAL.....	51
FIGURA 7.2: ESQUEMA FUNCIONAMIENTO DE UNA NEURONA, FUNCIÓN DE ACTIVACIÓN.....	52
FIGURA 7.3: FUNCIÓN LINEAL.....	53
FIGURA 7.4: FUNCIÓN ESCALÓN.....	53
FIGURA 7.5: FUNCIÓN LOGÍSTICA.....	54
FIGURA 7.6: FUNCIÓN TANGENTE HIPERBÓLICA.....	54
FIGURA 7.7: SUMATORIO DE ENTRADAS POR LOS PESOS SINÁPTICOS.....	55
FIGURA 7.8: FUNCIÓN DE SALIDA.....	56
FIGURA 7.9: APRENDIZAJE SUPERVISADO.....	56
FIGURA 7.10: ESQUEMA DE FUNCIONAMIENTO DE UN APRENDIZAJE POR CORRECCIÓN DEL ERROR.....	57

Capítulo 8

FIGURA 8.1: GRÁFICO DE LA SUPERFICIE DEL ERROR.....	67
---	----

Capítulo 9

FIGURA 9.1: BANCO DE PRUEBAS AMORTIGUADOR MR.....	69
FIGURA 9.2: CONJUNTO DE PATRONES DE ENTRENAMIENTO.....	71
FIGURA 9.3: CONJUNTO DE PATRONES DE VALIDACIÓN.....	71
FIGURA 9.4: TIPOLOGÍA 4_20_1.....	73
FIGURA 9.5: GRÁFICO DE ERROR RED 4_20_1.....	74
FIGURA 9.6: GRÁFICO DE ERROR 1 RED 4_20_1.....	75
FIGURA 9.7: GRAFICO DE ERROR 2 RED 4_20_1.....	76
FIGURA 9.8: TIPOLOGÍA 4_20_20_1.....	77
FIGURA 9.9: GRÁFICO DE ERROR 3 RED 4_20_20_1.....	78
FIGURA 9.10: GRÁFICO DE ERROR 4 RED 4_20_20_1.....	79
FIGURA 9.11: GRÁFICO DE ERROR 5 RED 4_20_20_1.....	80
FIGURA 7: GRAFICO DE ERROR 6 RED 4_20_20_1.....	80
FIGURA 813: TIPOLOGÍA 4_20_20_20_1.....	81
FIGURA 9.14: GRÁFICO DE ERROR RED 4_20_20_20_1.....	82
FIGURA 9.15: GRAFICO DE ERROR 1 RED 4_20_20_20_1.....	83
FIGURA 9.16: GRÁFICO DE ERROR 2 RED 4_20_20_20_1.....	84

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

FIGURA 9.17: GRAFICO DE ERROR 3 RED 4_20_20_20_1.....	85
FIGURA 9.18: GRAFICO DE ERROR 4 RED 4_20_20_20_1.....	86
FIGURA 9.19: GRAFICO DE ERROR 5 RED 4_20_20_20_1.....	86
FIGURA 9.20: GRAFICO DE ERROR 6 RED 4_20_20_20_1.....	87
FIGURA 9.21: GRAFICO DE ERROR 7 RED 4_20_20_20_1.....	88
FIGURA 9.22: TOPOGOLOGÍA 4_30_30_30_1.....	90
FIGURA 9.23: GRÁFICO DE ERROR RED 4_30_30_30_1.....	91
FIGURA 9.24: GRÁFICO DE ERROR 1 RED 4_30_30_30_1.....	92
FIGURA 9.25: GRAFICO DE ERROR 2 RED 4_30_30_30_1.....	93
FIGURA 9.26: GRAFICO DE ERROR 3 RED 4_30_30_30_1.....	94
FIGURA 9.27: GRÁFICO DE ERROR 4 RED 4_30_30_30_1.....	95
FIGURA 9.28: GRÁFICO DE ERROR 5 RED 4_30_30_30_1.....	96
FIGURA 9.29: ERRORES NUMÉRICOS DE ENTRENAMIENTO Y VALIDACIÓN 4_30_30_30_1.....	97
FIGURA 9.30: ERRORES NUMÉRICOS DE ENTRENAMIENTO Y VALICACIÓN 4_30_30_30_1.....	98
FIGURA 9.31: INTENSIDAD DESEADA FRENTE A INTENSIDAD DE RED NEURONAL.....	99

ÍNDICE DE TABLAS

TABLA 1: FACTORES DE APRENDIZAJE PARA 4_20_1.....	73
TABLA 2: FACTORES DE APRENDIZAJE 0.01 Y 0.001 PARA 4_20_1.....	75
TABLA 3: FACTORES DE APRENDIZAJE PARA 4_20_20_1.....	77
TABLA 4: FACTORES DE APRENDIZAJE 1 PARA 4_20_20_1.....	79
TABLA 5: FACTORES DE APRENDIZAJE PARA 4_20_20_20.....	82
TABLA 6: FACTORES DE APRENDIZAJE 1 PARA 4_20_20_20_1.....	84
TABLA 7: FACTORES DE APRENDIZAJE 2 PARA 4_20_20_20_1.....	85
TABLA 8: FACTORES DE APRENDIZAJE 3 PARA 4_20_20_20_1.....	87
TABLA 9: FACTORES DE APRENDIZAJE 4_30_30_30_1.....	91
TABLA 10: FACTORES DE APRENDIZAJE 1 4_30_30_30_1.....	93
TABLA 11: FACTORES DE APRENDIZAJE 2 4_30_30_30_1.....	95
TABLA 12: ERRORES DE ENTRENAMIENTO Y VALIDACIÓN 4_30_30_30_1.....	97
TABLA 13: ERRORES DE ENTRENAMIENTO Y VALIDACIÓN 4_20_20_20_1.....	98

CAPÍTULO 1: INTRODUCCIÓN

Hoy en día la suspensión de un vehículo juega un papel muy importante, tanto en la estabilidad como en el confort de los ocupantes. Existen tres tipos de suspensión, en primer lugar la suspensión pasiva, la suspensión activa y la suspensión semi-activa. La suspensión pasiva es la más simple de todas, al constar esta de un amortiguador normalmente de aceite y un muelle helicoidal. Las suspensiones activas y semi-activas presentan una mayor complejidad pero también unos mejores resultados. De la suspensión activa cabe mencionar que controla la estabilidad de cada rueda de manera independiente y consume una gran energía ya que tiene que ser dotada de una gran cantidad de sensores, que detecten las variables producidas durante la circulación del vehículo, y de actuadores, que actúen en consecuencia a las variables detectadas. Este sistema complejo de actuadores y sensores encarece considerablemente el precio de la suspensión, por tanto debe manejarse otra opción, como puede ser la suspensión semi-activa.

Una de las principales líneas de investigación es la de instalar amortiguadores magneto-reológicos(MR) en las suspensiones semi-activas, ya que este tipo de amortiguadores responden, variando su esfuerzo viscoso ante un campo magnético aplicado. Los sensores ubicados estratégicamente detectan una serie de variables tales como fuerza aplicada en el amortiguador, su velocidad, su desplazamiento y su frecuencia, por tanto debe hacerse pasar una corriente por el interior del amortiguador que genere un campo magnético en respuesta a las variables citadas. Existen diferentes modelos que consiguen establecer una relación entre la fuerza y la intensidad de corriente. Por un lado se encuentran los modelos directos, los cuales pretenden encontrar la relación entre la frecuencia, amplitud y corriente con la fuerza. Entre los modelos directos, se encuentran los modelos paramétricos, basados en ecuaciones diferenciales o algebraicas, y modelos no paramétricos. En el otro lado, se encuentran los modelos inversos que relacionan la fuerza, la frecuencia y la amplitud con la corriente que se debe hacer pasar por el amortiguador MR.

En este Trabajo de Fin de Grado se presenta un amortiguador magneto-reológico basado en redes neuronales, debido a que las redes neuronales son un recurso óptimo para establecer una relación no lineal entre la fuerza, frecuencia y desplazamiento frente a la intensidad de corriente.

1.1 OBJETIVO

El objetivo de este Trabajo de Fin de Grado es el de desarrollar un modelo inverso de amortiguador magneto-reológico basado en redes neuronales, con la finalidad de obtener la intensidad con la que se debe alimentar el amortiguador para que ejerza la fuerza indicada por el controlador.

Con las redes neuronales se pretende establecer una relación entre la fuerza, el desplazamiento, la velocidad y la frecuencia con la intensidad deseada. Para ello se realizan los siguientes pasos:

- En primer lugar se genera un patrón entrenamiento y de validación de la red.
- En segundo lugar se diseñan las distintas tipologías de la red.
- En tercer lugar se entrenan a las distintas redes neuronales, variando los factores de aprendizaje debidamente.
- Por último lugar, se observa el error cometido por las distintas redes y aquella cuyo error sea menor, es la red neuronal óptima para establecer la relación mencionada con anterioridad.

2.1 ESTRUCTURA DEL PROYECTO

El Trabajo de Fin de Grado consta de los siguientes 10 capítulos:

En el capítulo 1 “Introducción” en la cual se quiere hacer hincapié en los principales objetivos que se quieren conseguir.

En el capítulo 2 “Componentes de una suspensión vehicular” se explica los diferentes componentes de la suspensión de un vehículo, ya que es necesario definir dónde se ubica el amortiguador en la suspensión.

En el capítulo 3 “Tipos de suspensión: activa, pasiva, semi-activa” se explica las diferentes suspensiones de los vehículos y en cuál se instala el amortiguador magneto-reológico (MR).

En el capítulo 4 “Fluidos magneto-reológicos” se explica el funcionamiento de los mismos ya que en el interior de los amortiguadores MR se alberga dicho fluido. Por tanto es necesario definir sus propiedades y funcionamiento.

En el capítulo 5 “Modelos directos no paramétricos de amortiguadores MR” se explica en qué consiste un modelo directo de amortiguador MR y las ecuaciones que tratan de modelar su comportamiento.

En el capítulo 6 “Modelo inverso no paramétrico de amortiguadores MR” se explica cómo se encuentra el estado del arte y las diferentes metodologías para un modelo inverso de amortiguador MR.

En el capítulo 7 “Redes neuronales” se explica brevemente el funcionamiento de las redes neuronales.

En el capítulo 8 “Aprendizaje Backpropagation” se explica en qué consiste dicho aprendizaje, ya que va a ser empleado durante el entrenamiento de la red neuronal.

En el capítulo 9 “Datos experimentales en entrenamiento de red multicapa” se explica cómo se ha entrenado a las diferentes tipologías de red y se analiza el error cometido para tomar decisiones.

En el capítulo 10 “Conclusiones y trabajos futuros” se explica a qué conclusiones se ha llegado después de entrenar a la red, y que mejoras se pueden realizar mediante estudios futuros.

CAPÍTULO 2: COMPONENTES DE UNA SUSPENSIÓN VEHICULAR

2.1 INTRODUCCIÓN

En primer lugar, es necesario definir los diferentes componentes de una suspensión y a partir de aquí, conocer los tipos de suspensión y tecnologías que las mejoren.

El sistema de suspensión tradicional se compone de un elemento flexible o elástico, cuya misión es la de soportar la masa suspendida y que pueden ser una barra de torsión, un muelle de goma, de gas o de aire, o un muelle de ballesta o helicoidal. También consta de un sistema de amortiguación.

Los elementos flexibles presentan unas muy buenas propiedades elásticas pero su capacidad para absorber energía mecánica es muy deficiente, por este motivo, no pueden ser ubicados solos en la suspensión de un vehículo, necesitan de un elemento que absorba esa energía mecánica, y ese elemento es el amortiguador. Típicamente los amortiguadores que se montan con los sistemas elásticos son de doble efecto para que estos puedan trabajar tanto a compresión como en tracción [1].

2.2 ELEMENTOS ELÁSTICOS DE LA SUSPENSIÓN

En este apartado, se describen brevemente los diferentes elementos elásticos que pueden formar parte de una suspensión vehicular.

2.2.1 BALLESTAS

Las ballestas están formadas de láminas de acero especial para muelles unidas mediante unas abrazaderas que permiten que estas deslicen entre ellas cuando se encuentran sometidas a una cierta deformación. La lámina superior, llamada hoja o lámina maestra, se encuentra curvada en sus extremos en los que se montan unos casquillos para poder acoplar la ballesta al bastidor del vehículo. El acoplamiento se realiza mediante bulones o pernos, siendo estos diseñados para poder soportar los esfuerzos a los que se encuentran sometidos.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

En la figura 2.1 puede verse un ejemplo de este tipo de elemento elástico.




FIGURA 2.1: BALLESTA.

El número de hojas o láminas y el espesor de las mismas, se valora en función de la carga que estas vayan a soportar. Funcionan como los muelles de suspensión, ya que son los elementos de unión entre las ruedas y el bastidor. Estos elementos elásticos son empleados sobre todo en camiones y en vehículos ferroviarios.

2.2.1.1 MONTAJE DE LAS BALLESTAS

A continuación, se enumera los diferentes tipos de montaje de ballestas [1]:

- **Montaje longitudinal.** Este tipo de montaje se emplea fundamentalmente en camiones o autocares. Estos montajes se realizan ubicando la ballesta en un punto fijo y en un punto móvil, para permitir los movimientos oscilantes. El montaje con el punto fijo, se realiza montando este sobre el bastidor del vehículo, y el montaje con el punto móvil se realiza situando entre la ballesta y el bastidor, un elemento conocido como gemela de ballesta. (Ver figura 2.2).




FIGURA 2.2: BALLESTA CON MONTAJE LONGITUDINAL.

El montaje de la ballesta sobre el eje, puede realizarse como en la figura 2.2 en la que la ballesta se encuentra por encima del eje, o con el eje sobre la ballesta,

tal y como puede verse en la figura 2.3. Este último montaje permite que la carrocería se encuentre más cercana a la superficie y mejore la estabilidad.




FIGURA 2.3: BALLESTA UBICADA POR DEBAJO DEL EJE.

- **Montaje transversal.** Este tipo de montaje es el más empleado en los turismos, se realiza uniendo los extremos de la ballesta a los brazos de suspensión, con interposición de elementos móviles y la base de la ballesta a una traviesa del bastidor o carrocería. (Ver figura 2.4).




FIGURA 2.4: BALLESTA CON MONTAJE TRANSVERSAL.

2.2.2 MUELLES HELICOIDALES

Los muelles helicoidales son los más empleados en la mayor parte de los vehículos turismo, a diferencia de las ballestas, ya que estos consiguen una elasticidad blanda debido al gran recorrido del resorte si ocupar el espacio que ocupan las ballestas, y disminuyendo el peso considerablemente.

Los muelles helicoidales constan de un arrollamiento elástico de acero formado por un hilo cuyo diámetro es variable, la variación del diámetro depende de la tensión que tienen que soportar.

Los muelles helicoidales no transmiten esfuerzos laterales, por tanto necesitan montar bielas de empuje lateral y transversal para poder absorber las reacciones provocadas en la rueda. Este tipo de muelles trabajan a torsión generando en la sección de las espiras tensiones tangenciales. Cuando se le aplica una fuerza vertical estos se comprimen o se traccionan en función del sentido de la fuerza aplicada, disminuyendo o aumentando su longitud. Un ejemplo de lo que les ocurre a este tipo de muelles puede verse en la figura 2.5.




FIGURA 2.5: MUELLE HELICOIDAL

La rigidez de los muelles helicoidales es función del número de espiras, del diámetro y espesor del hilo, y del material del que esté compuesto. Para poder aumentar la rigidez de los muelles, a veces, se colocan uno o varios muelles en paralelo (ver figura 2.6), con diferente longitud libre con el objetivo de que la rigidez varíe solo en determinadas ocasiones, cuando la carga provoca una sollicitación de mayor rigidez [1].




FIGURA 2.6: DOS MUELLES HELICOIDALES EN PARALELO.

2.2.3 BARRAS DE TORSIÓN

Las barras de torsión se emplean en algunos vehículos con suspensión independiente, se basa en el principio, en el que si a una barra de acero, que está unida

por sus extremos a otro elemento al cual se le aplica un momento torsor, la barra de acero se retuerce y tiende a posicionarse en su posición de equilibrio. El brazo que es el elemento que se ajusta en las ruedas, cuando sufre un desplazamiento debido a las irregularidades del terreno, genera un momento torsor en la barra de acero, cuya deformación elástica permite el desplazamiento de la rueda, volviendo a su posición de equilibrio cuando el esfuerzo cesa. Un ejemplo de los diferentes montajes de las barras de torsión se muestra en la figura 2.7.




FIGURA 2.7: BARRAS DE TORSIÓN.

2.3 BARRA ESTABILIZADORA

Las barras estabilizadoras son importantes en la suspensión de un vehículo cuando este pasa por curva. Al circular por una curva el vehículo experimenta una fuerza centrífuga que provoca que las ruedas exteriores soporten un mayor peso, dando lugar a que el vehículo con sus ocupantes se incline en exceso, dando lugar a una situación de posible vuelco. Para evitar este efecto se colocan las denominadas barras estabilizadoras.

Las barras estabilizadoras consisten en una barra de acero de gran elasticidad cuyos extremos son fijados a los soportes de la suspensión. Cuando se circula por curva, una de las ruedas tiende a subir y a la otra a bajar, lo que provoca un par de torsión que es absorbido por la barra estabilizadora, que se opone al vuelco del coche.

En la figura 2.8 se muestra una imagen de una barra estabilizadora.




FIGURA 2.8: FUNCIONAMIENTO BARRA ESTABILIZADORA.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

En la figura 2.9 se muestra una imagen en la que puede verse la posición que ocupa la barra estabilizadora en la suspensión de un vehículo.




FIGURA 2.9: BARRA ESTABILIZADORA Y MUELLES DE SUSPENSIÓN.

2.4 COJINETES ELÁSTICOS Y SILENTBLOCKS

Los “silentblocks” son los encargados de amortiguar las reacciones que se producen en los apoyos de la suspensión. Normalmente están fabricados de caucho o cualquier material elástico que absorba como es debido los esfuerzos.

Los cojinetes elásticos son elementos que están fabricados al igual que los anteriores por caucho, y son los encargados de la unión entre los elementos de la suspensión, teniendo un pequeño deslizamiento. El montaje suele realizarse mediante bridas o casquillos. Los cojinetes elásticos son los más empleados para el montaje de las barras estabilizadoras en la suspensión. (Ver figura 2.10).




FIGURA 2.10: COJINETE ELÁSTICO EN BARRA ESTABILIZADORA.

2.5 MANGUETA

La mangueta de la suspensión es una única pieza fabricada de acero que une a la rueda con todos los elementos de la suspensión, barra estabilizadora, muelles, amortiguadores, etc. La mangueta es diseñada teniendo en cuenta el tipo de vehículo sobre el que se monta y sus dimensiones. Un ejemplo de la unión entre la mangueta y el muelle y los amortiguadores puede verse en la figura 2.11.




FIGURA 2.11: MANGUETA Y CONJUNTO MUELLE-AMORTIGUADOR.

2.6 RÓTULAS

Las rótulas son el elemento de unión y fijación de la suspensión y de la dirección. Las rótulas son instaladas en la suspensión para permitir que las ruedas puedan girar y pivotar manteniendo su propia geometría. Es importante llevar un estricto control de su estado, y sustituirlas cuando es debido. (Ver figura 2.12).



FIGURA 2.12: RÓTULA.

2.7 TRAPÉCIOS

Los trapecios son brazos articulados que soportan al vehículo a través de la suspensión. Están fabricados de chapa de acero o en fundición. Unen la mangueta y el buje al vehículo mediante los “silentblocks” y las rótulas, soportando todos los esfuerzos generados durante la trayectoria del vehículo por carretera.

En la figura 2.13 se muestra un ejemplo de la disposición de los trapecios en la suspensión de un vehículo.




FIGURA 2.13: TRAPÉCIOS DE SUSPENSIÓN.

2.8 AMORTIGUADORES

Los amortiguadores son los elementos encargados de absorber las vibraciones producidas por todos los elementos elásticos que conforman la suspensión (barras de torsión, muelles, ballestas), convirtiendo en calor la energía generada por las oscilaciones de los elementos elásticos.

Cuando el vehículo circula por una calzada irregular y la rueda encuentra un obstáculo, el muelle se comprime o estira, en función del tipo de obstáculo, recogiendo esta la energía mecánica producida por el choque, energía que devuelve a la carrocería del vehículo. Si no existieran los amortiguadores, el rebote en forma de vibración sería casi indefinido, no es infinita la vibración ya que el rozamiento con el aire, provocaría que la oscilación de vibración terminara en algún momento. Por tanto, la principal función de los amortiguadores es reducir las vibraciones el menor tiempo posible.

Los amortiguadores deben absorber las vibraciones tanto a tracción como a compresión, lo que provoca, que la mayor parte de los amortiguadores sean de doble efecto.

Los amortiguadores pueden ser “fijos” o “regulables”, los primeros tienen siempre la misma naturaleza y los segundos su naturaleza puede ser cambiada según unas determinadas condiciones.

Existen diferentes tipos de amortiguadores:

- **Los amortiguadores hidráulicos convencionales.** Estos pueden ser mono-tubo y bi-tubo.
- **Amortiguadores con gas.** Al igual que los anteriores también pueden ser mono-tubo y bi-tubo.

2.8.1 AMORTIGUADORES HIDRÁULICOS CONVENCIONALES

En los amortiguadores hidráulicos convencionales el control de las vibraciones generadas por la masa suspendida y la masa no suspendida, se realiza haciendo pasar un fluido viscoso, típicamente aceite, por unos pasos calibrados situados en la cabeza de émbolo. Son los más usuales, y presentan una gran pérdida de rendimiento cuando trabajan durante gran número de veces, esto es debido a que aumenta su temperatura y genera una disminución de sus propiedades.

Los amortiguadores de tipo telescópico, constan de un cilindro, dentro del cual se puede deslizar a través del fluido interior un émbolo, unido al vástago que termina, normalmente en un anillo que va unido a la carrocería del vehículo. Si el amortiguador es bi-tubo en lugar de un solo cilindro, aparecen dos cilindros concéntricos ambos sellados por la parte de arriba con el objetivo de mantener la estanquidad del fluido interior.

Tal y como puede verse en la figura 2.14, el amortiguador bitubo consta de tres cámaras, una por la parte superior del émbolo, otra por la parte inferior, y la tercera que es la zona existente entre los dos cilindros concéntricos. En todas las tres cámaras hay fluido, el cual normalmente es aceite [2].

Cuando la rueda pasa por un determinado bache, el embolo comprime el fluido y este se hace pasar por los pasos calibrados, aumentando la viscosidad, produciendo un efecto retardador de la vibración.

Es muy importante, tener en cuenta la temperatura ambiente en la que se encuentra trabajando el amortiguador, y el calor absorbido por los amortiguadores, ya que el calor influye sobre la viscosidad del fluido, provocando que este pase con una mayor o menor facilidad por los pasos calibrados. Por este motivo, en invierno cuando las temperaturas son bajas, el fluido presenta una mayor dificultad para pasar por los pasos calibrados, dando lugar a una suspensión más dura. Al contrario ocurre en verano, en la que la facilidad del fluido para pasar por las obstrucciones mencionadas, es mayor y por tanto su suspensión es mucho más blanda.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES




FIGURA 2.14: AMORTIGUADOR HIDRÁULICO BITUBO.

Existen otros sistemas de control de paso del fluido además de los orificios calibrados, como pueden ser los amortiguadores controlados por válvulas, tal y como puede verse en la figura 2.15.




FIGURA 2.15: AMORTIGUADOR HIDRÁULICO CONTROLADO POR VÁLVULAS.

Los amortiguadores hidráulicos convencionales presentan el inconveniente de que se pueden formar bolsas de aire bajo unas determinadas condiciones:

- Si el amortiguador se transporta horizontal durante su transporte.

- El aceite presente en la cámara principal cae por gravedad cuando el vehículo permanece en reposo durante largos periodos de tiempo.
- El aceite se contrae como consecuencia del enfriamiento y succiona aire hacia la cámara principal.

Estas desventajas, dan lugar al desarrollo de los amortiguadores presurizados.

2.8.2 AMORTIGUADORES PRESURIZADOS.

Los amortiguadores presurizados son empleados para mejorar las prestaciones de los amortiguadores bitubo hidráulicos convencionales. Estos consisten en añadir una cámara de presión de gas a 4 bares, en el cilindro concéntrico exterior.

En la figura 2.16, se muestra una comparativa entre un amortiguador no presurizado y otro presurizado.




FIGURA 2.16: AMORTIGUADORES BITUBO PRESURIZADO Y NO PRESURIZADO.

Los amortiguadores presurizados presentan una serie de ventajas frente a los amortiguadores no presurizados, que son:

- Las respuestas de las válvulas son más sensibles para pequeñas amplitudes de desplazamiento.
- Reducción del ruido hidráulico.
- Mejores propiedades de amortiguación en calzadas muy irregulares.
- Mejor confort durante el viaje.

2.8.3 AMORTIGUADORES CON GAS.

Los amortiguadores con gas funcionan con el mismo principio de que los amortiguadores hidráulicos, pero contienen en uno de sus extremos gas a presión, este gas suele ser normalmente nitrógeno, a unos 25 bares de presión.

Estos amortiguadores presentan un pistón flotante, que separa el gas a presión del fluido viscoso, con la finalidad de que estos no se mezclen. Cuando se produce una perturbación en la marcha normal del vehículo, el émbolo comprime la cámara de gas, generando esta una respuesta ante el cambio de volumen experimentado, que hace pasar el fluido por los pasos calibrados, dando una respuesta muy silenciosa, y de mayor eficacia que en el caso de los amortiguadores hidráulicos convencionales [1].

Existen dos tipos de amortiguadores de gas:

- **Amortiguadores de gas no regulables:** Los amortiguadores no regulables son un tipo de amortiguador muy resistente, de alta durabilidad y eficacia. Presentan una mayor resistencia a la pérdida de rendimiento por aumento de temperatura. Suelen emplearse en vehículos de altas prestaciones, ya que es un amortiguador de elevada calidad.
- **Amortiguadores de gas regulables.** Los amortiguadores regulables, se les puede variar el tipo de tarado. Es un tipo de amortiguador con elevada tecnología, y es uno de los más empleados en los vehículos de competición y grandes prestaciones.

En la figura 2.17, puede verse la disposición de los amortiguadores de gas.




FIGURA 2.17.:AMORTIGUADOR DE GAS.

CAPTÍTULO 3: TIPOS DE SUSPENSIÓN: ACTIVA, PASIVA Y SEMI-ACTIVA

3.1 INTRODUCCIÓN.

En este capítulo se describen los tipos de suspensiones más usadas en el sector de la automoción.

3.2 SUSPENSIÓN PASIVA

La suspensión pasiva, es aquella que está conformada por un amortiguador y por un muelle con el objetivo de absorber las vibraciones y las irregularidades de la calzada por las que circula el vehículo, y poder asegurar su correcta estabilidad. Sin embargo, la suspensión puede ser más rígida para el caso de una amortiguación más deportiva, donde prima la estabilidad frente al confort.

El esquema simplificado de una suspensión pasiva es el que se muestra en la figura 3.1.




FIGURA 3.9: ESQUEMA SUSPENSIÓN PASIVA PARA UNA RUEDA.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

Si se desea una suspensión más confortable, la rigidez del amortiguador tiene que ser menor, es decir, la suspensión en su conjunto debe ser mas “blanda”.

Este tipo de suspensiones presentan el inconveniente de que su mayor o menor rigidez permanece constante ante cualquier situación en el movimiento del vehículo en su paso por un trazado.

Lo ideal sería que la suspensión pudiese adaptar su comportamiento a las diferentes situaciones durante un trayecto, siendo en ciertas ocasiones más dura para mantener la estabilidad en el paso por curva, y siendo más blanda en otras, donde no se vea tan comprometida la seguridad y prime más el bien estar y confort de los pasajeros. De este inconveniente surgió la idea de crear una suspensión que se adaptara a las diferentes condiciones.

También se intentó mejorar los problemas que producía la suspensión tradicional frente al cabeceo y balanceo. Para poner solución a esta problemática, surgió la suspensión activa.

3.3 SUSPENSIÓN ACTIVA

El objetivo de la suspensión activa es la de controlar el cabeceo y el balanceo de un automóvil mediante un sistema neumático o hidráulico. El correcto funcionamiento de este tipo de suspensión se logra gracias a la estrecha relación entre sensores y actuadores, estos últimos gobernados mediante un computador electrónico (sensores) encargado de monitorizar en todo momento el perfil de la carretera y enviar señales eléctricas a la suspensión trasera y delantera. Estas señales eléctricas activarán los actuadores proporcionando la fuerza necesaria para que el vehículo se comporte con la mejor estabilidad y el mejor confort posible. En la siguiente figura 3.2 puede observarse el esquema de una suspensión activa [3].

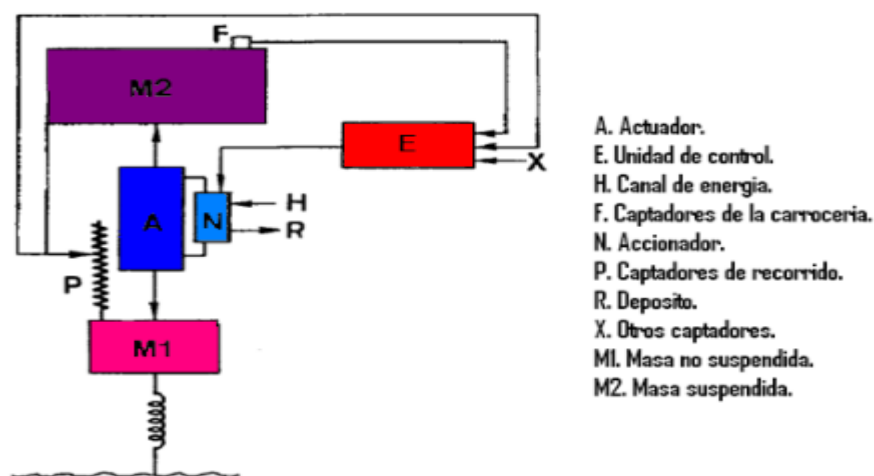


FIGURA 3.2: ESQUEMA DE SUSPENSIÓN ACTIVA.

La característica principal de este tipo de suspensión es que cada rueda tiene un control independiente lo cual hace que el vehículo tenga una mayor estabilidad, adherencia a la calzada y seguridad.

Cuando un vehículo con suspensión activa toma una curva, el sistema impide la inclinación del vehículo, es decir, evita el balanceo a su paso por curva. Lo mismo ocurre en las frenadas, un vehículo con suspensión pasiva o tradicional experimenta un cabeceo, sin embargo, con una suspensión activa, este hecho se evita, mejorando la calidad de la conducción. A parte de estas mejoras en el cabeceo y balanceo el sistema controla el reparto de cargas en los ejes delantero y trasero, distribuyendo las fuerzas en cada rueda, probando que el vehículo mantenga una altura fija sin que importe el nivel de carga. También con esta suspensión se consigue un mejor contacto neumático-calzada, mejorando la adherencia. Estas mejoras traen consigo un importante inconveniente, y es que su precio es más elevado que la suspensión tradicional.

Hay dos tipos de suspensiones activas, la suspensión de alta frecuencia y la de baja frecuencia.

3.3.1 HIGH BANDWIDTH

La suspensión “high bandwidth” tiene como objetivo controlar las vibraciones en todo el rango de frecuencias del sistema. El objetivo es mejorar la capacidad de respuesta de la suspensión en torno al “rattle-space” con una frecuencia (10-12Hz) y al “tire-hop” con una frecuencia (3 y 4Hz), ambos rangos de frecuencias pueden considerarse como las frecuencias de resonancia del sistema. Un sistema completamente activo, consumirá una gran cantidad de energía y requerirá actuadores con un gran ancho de banda de frecuencias. Este tipo de suspensión ha sido aplicado con un gran éxito en los coches de fórmula 1, como los lotus. En la figura 3.3 se muestra un esquema del funcionamiento de una suspensión “high bandwidth” [4].




FIGURA 3.10: ESQUEMA DE UNA SUSPENSIÓN ACTIVA HIGH BANDWIDTH.

3.3.2 LOW BANDWIDTH

La suspensión “low bandwidth” es un tipo de suspensión limitada a las bajas frecuencias, en torno a 3 y 4 Hz. En esta clase de suspensión el actuador se colocará en serie con un muelle y/o un amortiguador. Tiene como objetivo el control de frecuencias en el rango más bajo, ya que a frecuencias elevadas el actuador se bloquea. Con este tipo de sistemas se puede lograr una reducción significativa de la inclinación de la carrocería durante maniobras de frenado o paso por curva, con un menor consumo de energía que en el caso de las suspensiones “high bandwidth”. En la siguiente la figura 3.4 se muestran las dos posibles configuraciones de un esquema de suspensión “low bandwidth” [4].




FIGURA 3.11: ESQUEMA DE UN SISTEMA DE SUSPENSIÓN LOW BANDWIDTH.

3.4 SUSPENSIÓN SEMI-ACTIVA

La suspensión semi-activa se caracteriza por tener amortiguadores cuyo coeficiente de amortiguamiento es modificado por un control externo. Generalmente estas suspensiones controlan las frecuencias bajas con elementos activos y las frecuencias altas con elementos pasivos. Las no-linealidades de los amortiguadores semi-activos generan un comportamiento discontinuo de la fuerza que ocasiona un ruido audible, el cual se puede modificar a partir del algoritmo de control empleado.

La suspensión semi-activa se suele aplicar a vehículos ligeros. Asimismo, su rendimiento en trenes es comparable al de una suspensión activa y permite controlar su movimiento lateral.

Con este tipo de suspensión se quiere conseguir que esta se adapte tanto a condiciones de confort como a condiciones deportivas donde la suspensión es más dura, es decir, que la suspensión sea más dura o más blanda en función de las necesidades del conductor [3].

Un esquema de este tipo de suspensiones es el que se muestra en la figura 3.5.




FIGURA 3.12: ESQUEMA SUSPENSIÓN SEMI-ACTIVA.

Existen varias tecnologías en el uso de este tipo de suspensiones, una de ellas es la suspensión con amortiguadores bitubo pilotados con dos electroválvulas. Estas electroválvulas restringen o no el paso del fluido o aceite de una cámara a otra, variando la dureza de la suspensión. También realizan la función de permitir el paso de fluido entre las cámaras A y B a la cámara C (ver figura 2.6), provocando una situación de menor rigidez y más confortable.

Este tipo de suspensión necesita una gran variedad de sensores que le aporten las señales necesarias a la centralita, para que esta actúe sobre las electroválvulas correctamente.

Se necesita un acelerómetro longitudinal, que mida las aceleraciones experimentadas por el vehículo para poder actuar en consecuencia. Se necesita sensores en los pedales del freno, sensores captadores de velocidad y sensores que detecten oscilaciones verticales.

El principal inconveniente de los amortiguadores basados en electroválvulas son su tiempo de respuesta, del orden de 200 ms, es decir, superior a un ciclo de control. Por este motivo, surgen los amortiguadores magneto-reológicos, cuyo tiempo de respuesta es muy inferior, del orden de 20 ms.




FIGURA 2.13: ESQUEMA DE UN AMORTIGUADOR PILOTADO POR ELECTROVÁLVULAS.

3.4.1 SUSPENSIÓN SEMI-ACTIVA CON AMORTIGUADORES MR

Hoy día los amortiguadores MR están tomando mucha fuerza en el mercado de la automoción, debido al buen control sobre la variación de la viscosidad con la intensidad del campo magnético aplicado, y sobre todo a que sus tiempos de respuesta son inferiores a los amortiguadores pilotados por electroválvulas alcanzando tiempos de actuación de 20 ms.

Este tipo de amortiguadores presentan en su interior un líquido portador que puede ser aceite sintético o keroseno, con partículas magnéticas que sometidas a un campo magnético de mayor o menor intensidad, se alinean más o menos en función del campo aplicado, provocando una variación en la viscosidad del amortiguador y ejerciendo una determinada resistencia al movimiento del émbolo en el interior del amortiguador.

Cuando las partículas no se encuentran magnetizadas (modo OFF ver figura 3.7) y los momentos magnéticos que forman estas micropartículas están orientadas al azar el fluido MR se comporta como el fluido de un amortiguador convencional, pasando el fluido por los orificios del amortiguador a una velocidad mayor que el resto del fluido y por tanto, dotando al sistema de una gran suavidad.

Sin embargo, cuando las partículas son magnetizadas (modo ON ver figura 3.7) por un campo magnético exterior, estas se alinean formando estructuras y el fluido presenta una velocidad muy baja tanto en el interior de la cámara como en el paso por los orificios del émbolo, lo que produce que el sistema tenga una gran viscosidad y rigidez, esto se realiza cuando se quiere tener una suspensión más deportiva o más dura, o debido a que es necesario controlar el cabeceo del vehículo en una frenada brusca, o el balanceo en una curva. Por este motivo, los amortiguadores MR son de muy utilizados en los coches de competición, en los cuales es fundamental tener una gran estabilidad y control al paso por una curva.

El hecho de poder controlar la fuerza de amortiguamiento de un vehículo variando la intensidad de corriente, da lugar a un control de la suspensión a tiempo real.

En las suspensiones semi-activas tanto el amortiguador como el elemento elástico pueden cambiar su comportamiento, aunque normalmente suele hacerlo el amortiguador. Las suspensiones semi-activas controlan la fuerza de amortiguamiento en tiempo real, acorde a una estrategia de control, la cual se define sobre el sistema dinámico. El principal propósito de las estrategias de control es conseguir adaptar el amortiguador MR, en un sistema de suspensión semi-activa, para poder sustituir a las tradicionales suspensiones pasivas, o las costosas suspensiones activas.

En las suspensiones semi-activas, existe una línea de investigación que consiste en estudiar un modelo inverso de amortiguador MR, que consiga estimar la intensidad

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

de corriente deseada para ejercer la fuerza que el controlador le indica, a través de una serie de sensores ubicados estratégicamente en la suspensión del vehículo.

Tal y como se ha indicado en la introducción el objetivo de este Trabajo de Fin de Grado es conseguir un modelo inverso mediante el entrenamiento de redes neuronales.

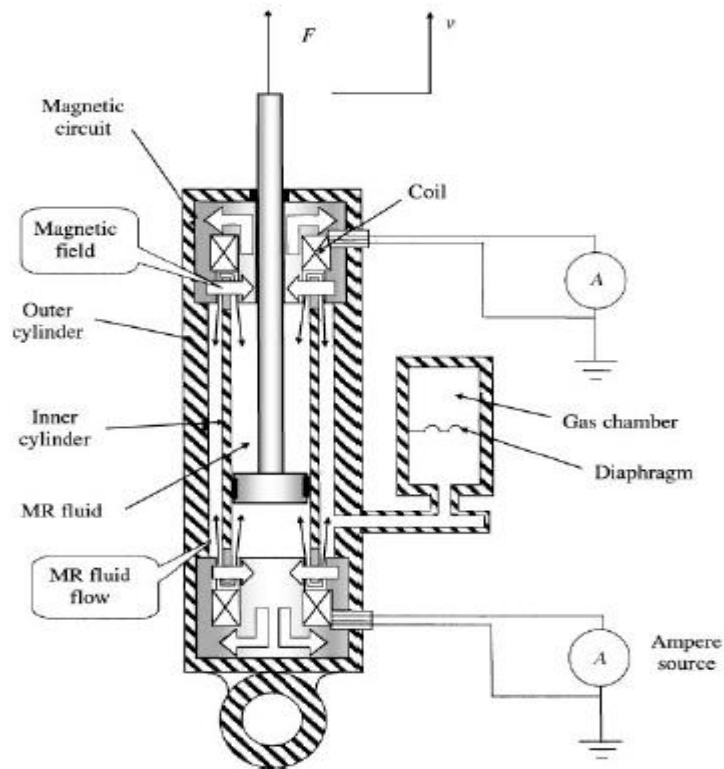


FIGURA 3.14: AMORTIGUADOR MR 1.

Su principal punto a favor, es su elevada rapidez de respuesta al tipo de amortiguación, adaptándose a una suspensión dura o blanda, según se requiera.

CAPÍTULO 4: FLUIDOS MAGNETO-REOLÓGICOS

4.1 INTRODUCCIÓN

Los fluidos magneto-reológicos (MR) son fluidos que contienen partículas superparagmanéticas en suspensión. Normalmente estos tipos de fluidos llevan un surfactante con el objetivo de reducir la tensión superficial y mejorar la suspensión de las partículas magnetizables.

Los fluidos MR los descubrió Jacob Rabinow [5] en el US National Bureau of Standards en los años cuarenta.

Cuando a los fluidos MR se les aplica un campo magnético, las partículas presentes en dicho fluido se alinean en la dirección del campo, variando considerablemente sus propiedades.

Los fluidos magnéticos cuando se encuentran en estado de reposo y no sufren ninguna excitación, presentan un comportamiento como el de la mayoría de los materiales o fluidos (como el aceite), es decir, un comportamiento newtoniano. Los fluidos newtonianos son aquellos cuya relación entre el esfuerzo de cizalla, y la velocidad de deformación es lineal, atendiendo a la siguiente ecuación [6].

$$\tau = \mu \frac{dv}{dy} \quad (4.1)$$

4.2 COMPORTAMIENTO DE UN FLUIDO MAGNETO-REOLÓGICO ANTE UN CAMPO MAGNÉTICO

Cuando este tipo de fluidos son excitados mediante la presencia de un campo magnético, las partículas en suspensión se alinean formando unas cadenas o estructuras columnares en dirección del campo magnético aplicado.

Si el campo se aplica en dirección perpendicular a la dirección del flujo, las cadenas formadas por las partículas se formarán en perpendicular a la dirección del fluido, dando lugar a una continua rotura y formación de dichas estructuras, lo que

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

provoca el aumento del esfuerzo en oposición al movimiento y por tanto se necesita una mayor energía mecánica para poder romper las estructuras columnares [6].

En la figura 4.1 puede apreciarse dicho efecto.




FIGURA 4.1: EFECTO DE UN CAMPO MAGNÉTICO A UN FLUIDO MR.

Cuando se le aplica el campo magnético, el fluido tiene un comportamiento reológico, y por tanto ante un esfuerzo inferior al de fluencia, se comporta como un fluido viscoelástico. Los fluidos reológicos presentan un esfuerzo de fluencia mayor que el de los fluidos newtonianos (ver figura 4.2), por lo que para conseguir una velocidad de deformación determinada, el esfuerzo que se tiene que realizar es mayor. El esfuerzo de fluencia en los fluidos reológicos es controlable mediante la intensidad del campo magnético, siendo mayor el esfuerzo de fluencia cuanto mayor es la intensidad del campo. En la figura 4.2 se muestra como varía el esfuerzo de fluencia en un fluido MR en función de la intensidad del campo magnético [6].




FIGURA 4.2: GRÁFICA ESFUERZO-DEFORMACIÓN.

4.3 PROPIEDADES MAGNÉTICAS

Las partículas en suspensión son superparamagnéticas, cuyos átomos tienen unos momentos magnéticos permanentes que interactúan entre sí pero de una manera muy débil. Cuando no existe ningún campo aplicado estos momentos se orientan al azar, sin embargo en presencia de un campo exterior, estos momentos magnéticos se alinean paralelos al campo aplicado.

El tamaño de estas partículas es del orden de 0.05 y 8 micras, para fluidos MR, siendo su tamaño un poco mayor para el caso de ferrofluidos. La principal ventaja de estas partículas, es que no presentan remanencia o histéresis, (a diferencia de otras partículas como las ferromagnéticas), por lo que al dejar de aplicar un campo magnético, las partículas se desmagnetizan por completo.

Los fluidos MR presentan unas propiedades magnéticas lineales, hasta un cierto valor, en torno a $0.02/\mu_0$ A/m, a partir del cual la permeabilidad del fluido permanece constante.

Esta permeabilidad constante se debe a que los fluidos MR presentan una saturación magnética

Los fluidos MR tienen alrededor de un 30% y un 40% de partículas de hierro en suspensión. Es de vital importancia en este tipo de fluidos la curva de imanación M en función del campo magnético aplicado H (ver figura 4.3), ya que a partir de un campo magnético, la magnetización deja de ser lineal alcanzando el valor de saturación, y esto se debe a que todos los momentos magnéticos de cada partícula son alineados con el campo magnético aplicado. Típicamente el valor de saturación en este tipo de fluidos se alcanza con un campo de 2.15 Teslas.

4.4 PROPIEDADES REOLÓGICAS

Las propiedades reológicas de los fluidos MR, son función de la densidad, concentración, tamaño y distribución de forma de las partículas, de las propiedades del fluido portador, que normalmente suele ser aceite mineral o aceite sintético, ya que son muy buenos lubricantes y evitan la sedimentación de las partículas de hierro y tienen una elevada durabilidad y estabilidad. También tienen una importante relevancia la temperatura, ya que la alineación de las partículas paramagnéticas está relacionada a parte de la intensidad del campo con la temperatura. La imanación de una partícula paramagnética es inversamente proporcional a la temperatura, por tanto a mayor temperatura, menor imanación, por tanto menos propiedades reológicas. Para conseguir unas correctas propiedades del fluido es necesario trabajar a bajas temperaturas, tal y como nos lo indica en su formulación la ley de Curie [7].

$$M = \frac{\mu * Bap * Ms}{3 * K * T} \quad (4.2)$$

donde:

- B_{ap} = Campo magnético aplicado.
- K = Constante de Boltzman.
- T = Temperatura.
- M_s = Imanación de saturación.
- μ = Momento magnético.




FIGURA 4.3: CURVA DE MAGNETIZACIÓN-CAMPO APLICADO

4.5 APLICACIONES DE FLUIDOS MAGNETOREOLÓGICOS

A continuación se enumeran las distintas aplicaciones de los fluidos magnetoreológicos.

4.5.1 AUTOMOTRIZ

En el sector automotriz, los fluidos MR se emplean en amortiguadores para el control de las vibraciones y mejorar el confort de los pasajeros en los vehículos. Los amortiguadores con este tipo de fluidos son de elevado interés ya que con un dispositivo electrónico se puede controlar rápidamente la rigidez del amortiguador.

Dichos fluidos también pueden emplearse en la suspensión de asientos de vehículos de trabajo pesado (ver figura 4.4), para emplearse en un sistema de suspensión semi-activa en vehículos de carga para trayectos largos [6].




FIGURA 4.4: AMORTIGUADOR MR 2.

4.5.2 ROBÓTICA

En robótica se suele emplear los fluidos MR para mover las articulaciones y las extremidades de los robots (ver figura 4.5) de tal manera que simule el movimiento de los seres humanos [3].



FIGURA 4.5: ROBOT CON ARTICULACIONES CON FLUIDOS MR.

4.5.3 CONTROL DE VIBRACIÓN SÍSMICA EN ESTRUCTURAS

En construcciones civiles también es muy importante el correcto control de vibraciones debido a ráfagas de viento, terremotos o seísmos, incluso la propia vibración que puede generar el paso de vehículos por determinadas estructuras en las que el control vibracional puede evitar que la estructura entre en resonancia y evitemos el derrumbamiento de la estructura [6].

Ya se emplea el uso de amortiguadores MR en China en el puente del lago Dong Ting, el cual está equipado con amortiguadores MR en los cables del puente, tal y como puede verse en la figura 4.6.




FIGURA 4.6: PUENTE DEL LAGO DONG TING.

4.5.4 APLICACIÓN DE UNA AMORTIGUADOR MR A LA SUSPENSIÓN DE UN VEHÍCULO AUTOMÓVIL

Los amortiguadores de los coches constan de un embolo unido a la carrocería con unos orificios por el que pasa el fluido viscoso, normalmente aceite, el paso del fluido por estos orificios provoca una resistencia, que controla las vibraciones ante una excitación externa. Además de los amortiguadores con orificios en el émbolo se han empleado sistemas de amortiguación de paso variable de aceite con electroválvulas. Pero se ha podido comprobar, que si en lugar de aceite empleamos un fluido MR con un control electrónico se obtienen unas resistencias mucho mayores y unos controles vibratorios mucho más rápidos a los obtenidos por el amortiguador con electroválvulas, teniendo un tiempo de respuesta diez veces menor que los convencionales (electroválvulas) [6].

La capacidad de cálculo y de programación del amortiguador MR nos aporta diferentes reacciones según la frecuencia de vibración de la rueda. De hecho, uno de los grandes avances en el empleo de estos amortiguadores frente a las electroválvulas es el rango de frecuencias de vibración, en torno a 1Hz y 4Hz. Uno de los coches más deportivos del mercado, ya incorpora este tipo de amortiguadores, y ese es el audi TT, ver figura 4.7.




FIGURA 4.7: AMORTIGUADOR MR PARA SEÍSMO.

CAPÍTULO 5: MODELOS DIRECTOS PARAMÉTRICOS DE AMORTIGUADOR MR

5.1 INTRODUCCIÓN

El control efectivo de un amortiguador MR depende principalmente de la comprensión de su comportamiento no lineal ya que este presenta histéresis cuando se le aplica un campo magnético. Por lo tanto es necesario desarrollar algoritmos de control para poder aprovechar al máximo las características del amortiguador, pero también estos modelos deben representar correctamente el comportamiento no lineal de dichos dispositivos.

Los modelos existentes pueden clasificarse en modelos paramétricos y modelos no paramétricos. Los modelos no paramétricos son capaces de modelar el comportamiento del amortiguador MR, pero los parámetros de sus ecuaciones no es necesario que tengan un significado físico. Algunos de estos modelos no paramétricos son los polinomios de Chebyshev [8,9], redes neuronales y neuro-fuzzy [10,11]. Estos tipos de modelos son altamente complejos y demandan una gran cantidad de datos experimentales para validar el modelo.

En el otro lado, se encuentran los modelos paramétricos, cuyas variables sí representan un fenómeno físico. Estos modelos consisten en algunos elementos mecánicos como amortiguadores, muelles, etc. Los parámetros asociados a estos elementos mecánicos están estimados mediante la comparación de estos modelos con los resultados experimentales. Uno de los primeros modelos no paramétricos es el modelo viscoelástico de Bingham desarrollado por Stanway [12]. En este modelo un elemento de fricción de Coulomb se coloca en paralelo con otro elemento viscoso, es decir, un amortiguador. Spencer [13] demostró que aunque este modelo podía describir el comportamiento fuerza-desplazamiento, sin embargo no podía describir la no linealidad existente en el comportamiento fuerza- velocidad. Gamota y Filisko [14] propusieron un modelo visco-elástico-plástico basado en modelo Bingham. Wereley

[15] propuso un modelo no lineal biviscoso con histéresis. Wilson [11] informó que este modelo y la mayoría de los descritos anteriormente podían describir el comportamiento de la fuerza-desplazamiento, pero no el comportamiento de la fuerza frente a la velocidad, y los bucles de histéresis.

Choi y Lee [16] propusieron un modelo polinomial y compararon los resultados obtenidos con los modelos de Bouc-Wen y Bingham, y demostró que su modelo predijo correctamente el comportamiento de histéresis. Este modelo presentaba un inconveniente y es que no representaba correctamente el comportamiento del amortiguador MR a bajas velocidades.

El modelo más empleado en el modelado de sistemas de histéresis es el modelo de Bouc-Wen. El modelo general de Bouc-Wen predice el comportamiento de la fuerza frente al desplazamiento y también el comportamiento fuerza-velocidad, que más se asemeja a los datos experimentales. Debido al error que presentaba a bajas velocidades la representación de velocidad-fuerza, Spencer propuso el modelo Bouc-Wen modificado.

Como Spencer generaliza su modelo modificado para campos magnéticos fluctuantes, este modelo es válido para cualquier corriente de excitación y campo magnético.

A partir del modelo Bouc-Wen modificado surgieron una serie de modelos paramétricos que representaban correctamente el comportamiento del amortiguador MR.

5.2 MEDIDAS EXPERIMENTALES EN EL AMORTIGUADOR MR

Se realiza una comparativa entre los resultados obtenidos por estos modelos y los resultados obtenidos experimentalmente mediante un amortiguador MR en un laboratorio de ensayos.

En la figura 5.1 se muestra un esquema del amortiguador empleado para obtener resultados experimentales.




FIGURA 15: AMORTIGUADOR MR 3.

El amortiguador MR al que se le realizan las pruebas, se conecta a una máquina que excitará al amortiguador con una serie de entradas, para poder computarizar las

salidas y obtener el comportamiento del amortiguador. El amortiguador a ensayar lleva una cantidad de sensores, tales como un sensor de temperatura, otro sensor de medición de desplazamiento y velocidad, y una célula de carga que mide la fuerza en el amortiguador. En este ensayo la fuerza a aplicar es de 22 KN. Las pruebas que se llevan a cabo para determinar la respuesta dinámica se realizan con diferentes intensidades de corriente a través de la bobina situada en el pistón. Las diferentes corrientes son de 0, 0.2, 0.4, 0.6, 0.8, 1, 1.5 y 2 A. Las velocidades de excitación son de 0.05, 0.1, 0.15, 0.2 m/s. Se obtuvieron 5200 datos, que fueron guardados en el software de la máquina [17].

Los datos experimentales obtenidos en el software de la máquina fueron enviados a un entorno Matlab, para poder compararlos con los modelos paramétricos.

5.3 MODELOS PARAMÉTRICOS PARA AMORTIGUADORES MR

Los modelos directos paramétricos pueden diferenciarse en dos grupos, los modelos basados en ecuaciones diferenciales ordinarias no lineales y los modelos basados en ecuaciones algebraicas.

5.3.1 MODELOS EVOLUTIVOS MEDIANTE ECUACIONES DIFERENCIALES ORDINARIAS

5.3.1.1 Modelo de Bouc-Wen: Uno de los primeros modelos empleados en la simulación del comportamiento dinámico de los amortiguadores MR. El modelo de Bouc-Wen es descrito por Spencer mediante las siguientes ecuaciones [17]:

$$F_0 = c_0 \dot{x} + k_0(x - x_0) + \alpha z \quad (5.1)$$

Donde la evolución temporal de la variable z puede expresarse de la siguiente manera:

$$\dot{z} = -\gamma z |\dot{x}| |z|^{n-1} - \beta \dot{x} |z|^n + A \dot{x} \quad (5.2)$$

Mediante el ajuste de los parámetros γ , β y A , puede modelarse correctamente el comportamiento dinámico.

En la figura 5.2 se muestra una representación del modelo.




FIGURA 16: MODELO BOUC-WEN

5.3.1.2 Modelo de Bouc-Wen modificado. Debido a que la respuesta no lineal de fuerza-velocidad del modelo Bouc-Wen no es totalmente correcta para bajas velocidades, se propuso el modelo de Bouc-Wen modificado. Este es representado mediante las siguientes ecuaciones [17]:

$$F = \alpha z + c_0(\dot{x} - \dot{y}) + k_0(x - y) + k_1(x - x_0) \quad (5.3)$$

Donde la evolución de z , atiende a la siguiente ecuación:

$$\dot{z} = -\gamma z |\dot{x}| |z|^{n-1} - \beta(\dot{x} - \dot{y})|z|^n + A(\dot{x} - \dot{y}) \quad (5.4)$$

Siendo:

$$\dot{y} = \frac{1}{(c_0 + c_1)} \{ \alpha z + c_0 \dot{x} + k_0(x - y) \} \quad (5.5)$$

Donde c_0 y c_1 representan la viscosidad a altas y bajas velocidades respectivamente. k_0 y k_1 indican la rigidez a altas y bajas velocidades respectivamente.

En la figura 5.3 se muestra una representación de este modelo.




FIGURA 17: MODELO BOUC-WEN MODIFICADO.

5.3.1.3. Modelo Bouc-Wen modificado de voltaje dependiente. Spencer propuso una versión del modelo anterior, en el que las corrientes aplicadas son fluctuantes generando campos magnéticos fluctuantes. A partir de las observaciones experimentales pudo afirmar que α , c_1 y c_0 , varían linealmente con la tensión de entrada aplicada. Propuso las siguientes ecuaciones [17]:

$$\alpha(u) = \alpha_a + \alpha_b u \quad (5.6)$$

$$c_1(u) = c_{1a} + c_{1b} u \quad (5.7)$$

$$c_2(u) = c_{2a} + c_{2b} u \quad (5.8)$$

5.3.1.4. Modelo de Dahl modificado. En este modelo Zhou y Qu[18] propusieron un modelo más simple y más eficaz que el de Dahl [19]. En este modelo se intenta simular la fuerza de Coulomb para evitar la estimación de demasiados parámetros. Este modelo fue creado para poder capturar la relación fuerza-velocidad en la región de bajas velocidades.

$$F_0 = K_0 x + C_0 \dot{x} + F_d z - f_0 \quad (5.9)$$

Donde K_0 es la rigidez del modelo, C_0 es el coeficiente de amortiguamiento, F_d es la fuerza de coulomb, x es el desplazamiento del amortiguador MR y f_0 es la fuerza del amortiguador.

En la siguiente expresión se describe la histéresis variable del modelo.

$$\dot{z} = \sigma \dot{x} (1 - z \cdot \text{sgn}(\dot{x})) \quad (5.10)$$

Donde, σ determina la forma del bucle de histéresis.

Es necesario determinar la variación de ciertos parámetros con la tensión aplicada de entrada. Las siguientes expresiones muestran dicha relación:

$$C = C_{0s} + C_{0d} u \quad (5.11)$$

$$F_d = F_{ds} + F_{dd} u \quad (5.12)$$

Donde C_{0s} y F_{ds} son el coeficiente de amortiguamiento y de Coulomb respectivamente, u es la variable para determinar la dependencia del voltaje aplicado (V) con los parámetros del modelo. La relación entre u y el voltaje aplicado, es modelado por Spencer mediante la siguiente expresión.

$$\dot{u} = -\eta(u - V) \quad (5.13)$$

Donde η refleja el tiempo de respuesta del amortiguador. El modelo tiene un conjunto de ocho parámetros ($C_{0s}, C_{0d}, F_{ds}, F_{dd}, K_0, \sigma$ y η) que deben ser obtenidos mediante datos experimentales [17].

En la figura 5.4 se muestra el modelo de Dahl [19] modificado.




FIGURA 18: MODELO DE DAHL MODIFICADO.

5.3.1.5. Modelo de fricción de Lugre modificado. Es una continuación del modelo de fricción propuesto por Dahl [19]. Su simplicidad matemática y alta precisión hace que este modelo sea un buen candidato en el modelado de un amortiguador MR. Sus expresiones matemáticas son las siguientes:

$$F = f_o + \beta z + \gamma \dot{x} + \delta x + \varepsilon \dot{z} \quad (5.14)$$

$$\dot{z} = \dot{x} - \alpha |\dot{x}| z \quad (5.15)$$

Donde α, β, γ y ε son parámetros de rigidez y amortiguamiento que pueden variar con la intensidad de corriente aplicada. F es la fuerza aplicada al amortiguador MR, x es el desplazamiento y z está relacionada con la deformación del fluido MR [17].

5.3.2 MODELOS ALGEBRAICOS

5.3.2.1. Modelo de Kwok. Kwok [20] Propuso un modelo en el que se usaba la tangente hiperbólica para representar la histéresis y la función lineal para representar la rigidez y la viscosidad. Las ecuaciones que gobiernan este modelo son las siguientes:

$$F = c \dot{x} + kx + \alpha z + f_o \quad (5.16)$$

$$z = \tanh[\beta \dot{x} + \delta \operatorname{sgn}(x)] \quad (5.17)$$

Donde c y k son los parámetros de viscosidad y rigidez respectivamente, α es un factor de escala de histéresis, z es la variable de histéresis dada por la función hiperbólica, y f_o es la fuerza del amortiguador [17].

En la figura 5.5 se muestra del modelo algebraico de Kwok [20].




FIGURA 19: MODELO ALGEBRAICO DE KWOK.

El efecto de cada parámetro en el ciclo de histéresis puede observarse en la figura 4.6.




FIGURA 20: CICLO DE HISTÉRESIS. VELOCIDAD FRENTE A LA FUERZA.

5.3.2.2 Modelo algebraico. Guo y Hu [21] propusieron un modelo algebraico para representar la histéresis del amortiguador MR. El modelo atiende a la siguiente ecuación.

$$F = f_0 + c_b \dot{x} + \frac{2}{\pi} f_y \tan^{-1} \{ k [\dot{x} - \dot{x}_0 \operatorname{sgn}(\ddot{x})] \} \quad (4.18)$$

Donde f es la fuerza en el amortiguador MR, f_0 es la fuerza de precarga del acumulador de gas, c_b es la constante de viscosidad, f_y es la fuerza aplicada, k es el coeficiente de forma, \dot{x}_0 es la velocidad de histéresis, y \dot{x} y \ddot{x} son la velocidad y aceleración del pistón en el amortiguador [17].

5.3.2.3 Modelo algebraico modificado. El modelo propuesto por Guo and Hu [21] proporcionaba unas salidas muy próximas a las deseadas, excepto en las entradas de corriente más bajas, es decir, las entradas de corriente de 0 y 0.2 A. Este error podía deberse a la fuerza de inercia del fluido, por lo que se añadió un nuevo término al modelo algebraico de Guo y Hu, con el objetivo de mejorar la simulación del comportamiento de los amortiguadores MR. Por tanto, el modelo algebraico sigue la siguiente expresión [17]:

$$F = f_0 + c_b \dot{x} + \frac{2}{\pi} f_y \tan^{-1} \{ k [\dot{x} - \dot{x}_0 \operatorname{sgn}(\ddot{x})] \} + m \ddot{x} \quad (5.19)$$

Siendo m la masa virtual que debe ser obtenida mediante datos experimentales.

5.4 COMPARACIÓN DE LOS MODELOS PARAMÉTRICOS FRENTE A UN CONJUNTO DE DATOS

De los ocho modelos paramétricos descritos anteriormente, es necesario conocer cuál de ellos simula mejor el comportamiento de un amortiguador MR y cuya resolución de las ecuaciones sea en el menor tiempo posible, es decir, que tenga una menor complejidad.

Para hacer una correcta evaluación de los modelos, Spencer propuso las siguientes expresiones para medir el error, $(E_t, E_x, E_{\dot{x}})$, que son los errores en función del tiempo, en función del desplazamiento y en función de la velocidad en dos ciclos completos respectivamente.

$$E_t = \sqrt{\frac{\int_0^T (F_{test} - F_{model})^2 dt}{\int_0^T (F_{test} - \mu F)^2 dt}} \quad (5.20)$$

$$E_x = \sqrt{\frac{\int_0^T (F_{test} - F_{model})^2 \left| \frac{dx}{dt} \right| dt}{\int_0^T (F_{test} - \mu F)^2 \left| \frac{dx}{dt} \right| dt}} \quad (5.21)$$

$$E_{\dot{x}} = \sqrt{\frac{\int_0^T (F_{test} - F_{model})^2 \left| \frac{d\dot{x}}{dt} \right| dt}{\int_0^T (F_{test} - \mu F)^2 \left| \frac{d\dot{x}}{dt} \right| dt}} \quad (5.22)$$

Donde F_{test} y F_{model} son las fuerzas del amortiguador obtenidas experimentalmente y mediante los modelos paramétricos respectivamente. μF es la fuerza media durante un período de prueba T.

En la figura 5.7 se muestra una tabla de los errores normalizados para los ocho modelos paramétricos con las diferentes velocidades de pistón (0.05, 0.10, 0.15, 0.2 m/s).

En el análisis de esta tabla, hay determinados aspectos a destacar. En términos de E_t , puede verse que el modelo algebraico de Kwok nos proporciona el error más bajo, siendo este de 0.0221. Cabe destacar, que los modelos paramétricos basados en ecuaciones diferenciales ordinarias, presentan errores más elevados que los modelos algebraicos, un ejemplo de esto, es el error que muestra el modelo de Bouc-Wen, de 0.053, mientras que los modelos modificados de este tienen un error de 0.0251(mBW) y 0.0241(vmBW), estos valores todos mayores que el modelo algebraico modificado y el modelo de Kwok, como puede verse en la tabla de la figura 4.7. En cuanto a los errores normalizados respecto del desplazamiento y de la velocidad puede observarse la misma

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

tendencia, en la que los modelos algebraicos siguen presentando un error medio inferior a los modelos complejos mediante ecuaciones diferenciales.

$v \text{ (m s}^{-1}\text{)}$	0.05	0.10	0.15	0.20	Average
E_t					
mDahl [22]	0.041	0.042	0.043	0.038	0.0410
Kwok [24]	0.026	0.021	0.018	0.023	0.0221
BW [3]	0.035	0.036	0.092	0.038	0.0503
mBW [3]	0.034	0.022	0.021	0.024	0.0251
vmBW [3]	0.032	0.022	0.022	0.020	0.0241
mLF [28]	0.038	0.031	0.031	0.034	0.0333
Alg [25]	0.034	0.023	0.021	0.025	0.0257
mAlg (this study)	0.035	0.022	0.021	0.016	0.0230
E_x					
mDahl [22]	0.004	0.006	0.008	0.009	0.0066
Kwok [24]	0.003	0.003	0.004	0.006	0.0042
BW [3]	0.004	0.005	0.016	0.008	0.0082
mBW [3]	0.004	0.004	0.005	0.007	0.0046
vmBW [3]	0.004	0.004	0.005	0.006	0.0043
mLF [28]	0.004	0.005	0.006	0.008	0.0059
Alg [25]	0.004	0.004	0.005	0.007	0.0048
mAlg (this study)	0.004	0.003	0.004	0.004	0.0038
$E_{\dot{x}}$					
mDahl [22]	0.018	0.036	0.056	0.064	0.0435
Kwok [24]	0.011	0.018	0.023	0.038	0.0230
BW [3]	0.015	0.031	0.122	0.065	0.0583
mBW [3]	0.015	0.019	0.025	0.038	0.0243
vmBW [3]	0.014	0.018	0.028	0.031	0.0230
mLF [28]	0.016	0.026	0.039	0.056	0.0343
Alg [25]	0.015	0.020	0.026	0.040	0.0251
mAlg (this study)	0.020	0.026	0.023	0.024	0.0230

FIGURA 21: ERRORES NORMALIZADOS PARA LOS DIFERENTES MODELOS.

Por tanto, se puede sacar la conclusión de que ambos modelos paramétricos presentan errores muy bajos, y que los modelos algebraicos son los más aceptables ya que presentan dos ventajas muy importantes. La primera es su bajo error como ya se ha comentado anteriormente, y la otra es su simplicidad en la resolución, ya que las ecuaciones algebraicas no necesitan tanta pericia y experiencia en la resolución de ecuaciones matemáticas como puede necesitarse para solucionar las ecuaciones diferenciales.

De los modelos paramétricos algebraicos, los que presentan un mejor resultado, y por tanto una mejor aproximación en la simulación del comportamiento de un amortiguador MR son los modelos Kwok y mAlg, como se puede apreciar en la figura 4.7.

Para poder plasmar gráficamente la validez del modelo algebraico modificado, este se compara con los datos obtenidos experimentalmente para diferentes valores de corrientes de entrada, para un valor máximo de velocidad de pistón, como puede verse en la figura 8 (a)-(d). En estas figura se puede sacar las conclusiones siguientes: aparte de las mencionadas anteriormente, puede verse que el modelo algebraico modificado, representa correctamente la histéresis presente en el amortiguador, problema que presentaban los modelos basados en ecuaciones diferenciales y que el modelo algebraico ha solventado.

En conclusión, los modelos paramétricos que más se aproximan al comportamiento deseado, son los que muestran la capacidad de modelar el comportamiento no lineal que presenta el amortiguador frente a un campo magnético aplicado. Los modelos que consiguen dicho objetivo son los algebraicos. Los modelos basados en ecuaciones diferenciales no presentan ninguna ventaja frente a los algebraicos, ya que su estimación de error es mayor, el cálculo es más complejo y se necesita una mayor cantidad de datos para obtener los parámetros del modelo.

Por lo tanto, el modelo algebraico modificado es totalmente válido en la simulación de un amortiguador MR, y por lo que este se puede aplicar en el control de vibraciones de estructuras y de suspensiones en el sector automotriz [17].

CAPÍTULO 6: MODELO INVERSO NO PARÁMETRICO DE AMORTIGUADOR MR

6.1 INTRODUCCIÓN

El modelo inverso de un amortiguador MR, es un modelo que puede predecir la intensidad o voltaje requerido de manera que el amortiguador pueda producir la fuerza deseada para el control de las vibraciones de un determinado sistema.

El modelo fenomenológico no lineal del amortiguador MR fue desarrollado por Spencer. Está basado en el modelo de histéresis de Bouc-Wen, que está dotado de la suficiente precisión matemática para simular su comportamiento. Usando este modelo matemático, se puede obtener la fuerza del amortiguador, conociendo el desplazamiento y el voltaje. Esto es conocido como el modelo directo. Sin embargo, la resolución de estas ecuaciones no lineales pueden ser complejas y emplear un tiempo excesivo en la resolución de las mismas. Por tanto para el modelo inverso, en lugar de un modelo matemático se empleará un sistema que pueda predecir directamente la intensidad necesaria.

Es posible realizar un modelo correcto de un amortiguador MR mediante el uso de redes neuronales ya que estas son muy eficientes en la generación de funciones no lineales.

En el uso de las redes neuronales es de vital importancia la arquitectura de la red, es decir, de cuantas capas va a estar formada, el numero de neuronas que conforman cada capa. Se ha demostrado en los últimos años, que aumentar el número de capas ocultas mejora la capacidad de aprendizaje de la red y el rendimiento de esta. También se ha de decir que un exceso de capas ocultas puede disminuir el rendimiento, por lo que con dos o tres capas ocultas es suficiente.

Existen dos maneras de mejorar el rendimiento de una red neuronal, la ya mencionada anteriormente, en la que se aumentaba el número de capas ocultas, la otra manera, en la que se emplea el *Optimal Brain Surgeon* (OBS) [22], en la que se eliminan los pesos superfluos de la red, dando lugar a una red neuronal mucho más óptima.

El entrenamiento de una red neuronal es el proceso basado en la entrada y salida de diferentes datos y cada uno de estos con un peso o una ponderación diferente. Los

algoritmos de aprendizaje se basan en la minimización de la función de error, que es la función del vector de pesos que son ajustados. Se emplean diferentes tipos de algoritmos de aprendizaje, se encuentra el de “gradient descent algorithm” [23], “backpropagation” “least-squares”, “recursive estimation” y el método de Lenverg-Marquardt [24] basado en el método de Gauss-Newton.

Las metodologías a emplear, y que se desarrollan más adelante, para la construcción de un modelo inverso son, el empleo de una óptima red neuronal y su entrenamiento y el sistema de identificación

Los datos para el entrenamiento y la validación de la red neuronal son obtenidos de la simulación del modelo matemático propuesto por Spencer [13].

Para construir un modelo inverso de un amortiguador MR, el voltaje, el desplazamiento y la fuerza serán seleccionadas como las variables de entrada (inputs), mientras que el voltaje será la variable de salida [25].

6.2 SIMULACIÓN DEL COMPORTAMIENTO DE UN AMORTIGUADOR MR.

Spencer propuso un nuevo modelo fenomenológico basado en una histéresis de Bouc-Wen para un prototipo de un amortiguador MR desarrollado por Lord Corporation. El modelo es gobernado, tal y como se mostró en el capítulo anterior, por las siguientes ecuaciones, que son a modo de resumen el modelo de Bouc-Wen modificado.

$$f = c_1 \dot{y} + k_1(x - x_0) \quad (6.1)$$

$$\dot{y} = \frac{1}{c_0 + c_1} [\alpha z + c_0 \dot{x} + k_0(x - y)] \quad (6.2)$$

$$\dot{z} = -\gamma |\dot{x} - \dot{y}| z |z|^{n-1} - \beta (\dot{x} - \dot{y}) |z|^n + A(\dot{x} - \dot{y}) \quad (6.3)$$

$$\alpha = \alpha_0 + \alpha_0 u \quad (6.4)$$

$$c_1 = c_{1a} + c_{1b} u \quad (6.5)$$

$$c_0 = c_{0a} + c_{0b} u \quad (6.6)$$

$$\dot{u} = -\eta(u - v) \quad (6.7)$$

Donde el significado de cada una de las constantes, fueron descritas en el capítulo anterior (Capítulo 5), este capítulo tiene como objetivo comparar el modelo paramétrico como es el de Bouc-Wen modificado con los modelos no paramétricos que se describen más adelante [25].

La mecánica de dicho modelo se muestra en la siguiente figura 6.1:




FIGURA 6.1. MODELO BOUC-WEN MODIDFICADO 2

Se han obtenido unos 14 parámetros para caracterizar el comportamiento del modelo del amortiguador MR. Estos 14 parámetros corresponden a las constantes de las ecuaciones [(5.1), (5.2), (5.3), (5.4), (5.5), (5.6), (5.7)], formuladas anteriormente. La obtención y optimización de todos los parámetros se ha obtenido experimentalmente realizando una elevada cantidad de pruebas. El resultado de los parámetros puede verse en la siguiente figura (ver Figura 6.2). De acuerdo al modelo que se muestra en la figura 6.1, la fuerza del prototipo de amortiguador es obtenida a partir del desplazamiento y de la tensión. Este modelo representa correctamente el comportamiento del amortiguador MR [25].

Parameter values of MR damper model

Parameter	Value	Parameter	Value
c_{0a}	21.0 N s/cm	α_a	140.0 N/cm
c_{0b}	3.50 N s/cm V	α_b	695.0 N s/cm V
k_0	46.9 N/cm	γ	363.0 cm ⁻²
c_{1a}	283.0 N s/cm	β	363.0 cm ⁻²
c_{1b}	2.95 N s/cm V	A	301.0
k_1	5.0 N/cm	n	2
x_0	14.3 cm	η	190 s ⁻¹

FIGURA 6.2: VALOR NUMÉRICO DE LAS CONSTANTES DEL MODELO PARAMÉTRICO.

En las siguientes figuras se muestra las entradas aplicadas al amortiguador, en primer lugar el desplazamiento, siendo este sinusoidal de frecuencia 2.5Hz y una amplitud de 1.5 cm. En segundo lugar se muestra el voltaje aplicado, siguiendo este una línea recta y ascendente desde 1.5 V hasta unos 2.5V aproximadamente, y por último se muestra la fuerza generada por el amortiguador MR [25].




FIGURA 6.3: DESPLAZAMIENTO Y VOLTAJE APLICADO. FUERZA OBTENIDA EN EL AMORTIGUADOR

En este tipo de modelo paramétrico, cabe reseñar que es un modelo directo de amortiguador MR, ya que se le está aplicando un voltaje (intensidad) a la bobina interior del émbolo del pistón, y un desplazamiento sinusoidal, para obtener la fuerza deseada de amortiguamiento.

En la figura 6.4 se muestra el bucle fuerza desplazamiento del modelo del amortiguador MR.




FIGURA 6.4: BUCLE FUERZA DESPLAZAMIENTO MODELO PARAMÉTRICO.

En la figura 6.5 se muestra los bucles de fuerza frente a la velocidad.




FIGURA 6.5: FUERZA-VELOCIDAD MODELO PARAMÉTRICO.

6.3 TÉCNICAS DE MODELIZACIÓN PARA AMORTIGUADOR MR

En este apartado se describen técnicas de modelización de amortiguador MR inverso. Estas técnicas no son las descritas hasta ahora mediante ecuaciones diferenciales no lineales, o mediante ecuaciones algebraicas.

Para simular el comportamiento del amortiguador inverso se empleará la técnica de las redes neuronales artificiales, pudiendo ser estas de varios tipos [25].

6.3.1 RED NEURONAL MLP

La red neuronal multicapa perceptrón (MLP) es el miembro más empleado en la familia de la red neuronal debido a que su capacidad para modelar es simple y sus relaciones funcionales son complejas. Un ejemplo de este tipo de redes, puede verse en la figura 6.6, una red completamente conectada, tipo de conexión feedforward con n neuronas de entrada, p neuronas de salida y m neuronas ocultas.




FIGURA 6.6: ARQUITECTURA RED NEURONLA MLP.

Para las redes MLP que solo tienen una capa oculta, con solo una función de activación sigmoide f_i y una función de activación lineal F_i , las salidas pueden ser expresadas en función de los pesos y de las entradas, atendiendo a la siguiente ecuación:

$$\hat{y}_i = F_i \left[\sum_{j=1}^q W_{ij} f_i \left(\sum_{k=1}^p w_{jk} u_k + w_{jo} \right) + W_{io} \right] \quad (6.8)$$

Los pesos W_{ij} y w_{ij} son pesos ajustables por la red (vector θ), siendo θ el vector de entradas a la red, y que se determinan a partir de un conjunto de datos mediante el entrenamiento de la red neuronal. Los datos de entrenamiento son un conjunto de entradas y salidas. La tangente hiperbólica es la función de activación (f) de la capa oculta. La función de esta curva es la siguiente:

$$f(x) = 1 - \frac{2}{1+e^{2x}} \quad (6.9)$$

El objetivo del entrenamiento de la red con el conjunto de datos de entrenamiento es poder asignar correctamente los pesos a la función \hat{y}_i , y la salida estimada de la red neuronal sea lo más cercana posible a la realidad [25].

6.3.2 ÓPTIMA ARQUITECTURA DE RED NEURONAL.

El llamado Optimal Brain Surgeon (OBS) [22] ofrece una opción automática para la optimización de la red neuronal. El OBS es un método importante y único que ha sido implementado en los modelos de sistemas dinámicos. El OBS se basa en obtener una red óptima mediante la eliminación o poda de los pesos superfluos de la red neuronal. Esta estrategia consiste en entrenar continuamente la red neural, pero cada vez eliminando un peso, considerado superfluo, hasta que se obtenga el menor error de entrenamiento.

La eliminación de un peso lleva consigo la eliminación de la conexión. La poda de los enlaces de una neurona con el resto de la topología de la red, provoca la eliminación de la neurona. Por lo tanto la poda de los pesos superfluos provoca una simplificación de la topología de la red neuronal mejorando la comprensión de los datos.

6.3.2.1 ESTIMACIÓN Y VALIDACIÓN DE LA RED NEURONAL.

Basándose en el desarrollo de las metodologías la red neuronal mostrada en la figura 6.6, que es entrenada usando los datos de la figura 6.3.

Es una red neuronal completamente conectada con doce neuronas en la capa oculta. Presenta seis neuronas de entrada, donde cada dos neuronas adquieren los valores del último y penúltimo valor de desplazamiento, frecuencia y voltaje, obteniendo a partir de su entrenamiento el voltaje deseado (Ver figura 6.7).




FIGURA 6.7: RED NEURONAL COMPLETAMENTE CONECTADA.

Empleando la tecnología de la poda o eliminación descrita anteriormente, se obtiene una red neuronal óptima donde han sido eliminados 83 pesos superfluos, es decir, un 85.5% del total de los pesos.




FIGURA 6.8: RED NEURONAL CON PESOS SUPERFLUOS ELIMINADOS.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

Una vez obtenida la red neuronal óptima, hay que observar y conocer si el valor obtenido por la red es muy próximo al deseado. Como el valor que se quiere obtener es la tensión necesaria para el modelo inverso del amortiguador MR, se debe comparar gráficamente el voltaje obtenido con la red y el voltaje deseado, esto puede verse en la siguiente figura. Ver figura 6.9.




FIGURA 6.9: VOLTAJE OBTENIDO POR LA RED NEURONAL ÓPTIMA.

La figura 6.9 informa sobre el voltaje obtenido con la red neuronal entrenada, si esta se compara con la figura 5.3 (observando el gráfico del voltaje), puede afirmarse que el resultado entre lo deseado y lo obtenido por la red neuronal es muy próximo. Por tanto la estrategia OBS en este caso, puede decirse que ha sido un éxito.

Otra manera de verificar si la red es lo suficientemente óptima es cuantificar el error entre las señales predichas y las deseadas. La siguiente expresión representa una manera de cuantificar los errores:

$$E_v = \frac{\sqrt{\sum_{s=1}^N [v_d(s) - v_p(s)]^2}}{\sqrt{\sum_{s=1}^N [v_d(s) - \mu_v]^2}} \quad (6.10)$$

Donde v_d es el voltaje deseado, v_p es el voltaje predicho por la red neuronal óptima y μ_v es el valor medio de la tensión deseada. Se obtuvo un valor del error normalizado de 0.0044, el cual es muy pequeño, por lo tanto puede afirmarse, también por este método que la metodología ha sido un éxito.

Aunque la red neuronal ha sido entrenada muy bien todavía tiene que ser validada por el uso de señales. De acuerdo con las características de uso de funcionamiento del amortiguador MR, dos conjuntos de señales se utilizan para verificar la red óptima.

El primer conjunto de señal se compone de un desplazamiento sinusoidal con una amplitud de 1 cm y una frecuencia de 5Hz, un voltaje constante de 1.0 V. La fuerza generada por el amortiguador MR es periódica e incrementándose con el tiempo. Este conjunto de señales puede verse en la siguiente figura 6.10.

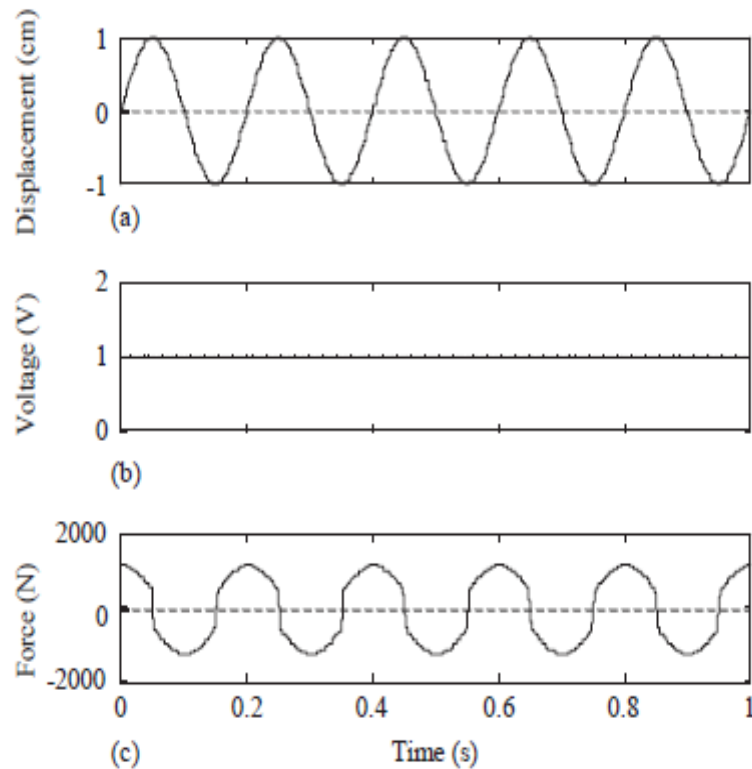


FIGURA 6.10: PRIMER CONJUNTO DE SEÑALES DE VALIDACIÓN.

El segundo conjunto de señales consiste en un desplazamiento aleatorio, el cual consta de un máximo desplazamiento de 1 cm y un mínimo de un -1 cm. El valor de la tensión es escalonado, variando entre los 0 V y los 3 V como máximo. La fuerza ejercida en el amortiguador magneto-reológico no sigue ningún patrón establecido, si no que sus señales se propagan al azar aumentando su valor máximo respecto del primer conjunto de señales, es decir, en el segundo conjunto de validación la fuerza oscila entre un máximo de 4000 N y un mínimo de -4000N.

Es muy importante, generar más de un conjunto de validación, y sobre todo, que alguno de estos conjuntos de validación sean variables generadas al azar, para comprobar que la red MLP ha sido entrenada correctamente, y que el método empleado en ello, como es en este caso, el “Optimal Brain Surgeon” es de éxito en este tipo de tareas.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

En la figura 5.11 puede observarse la forma de estas señales, al igual que en el primer conjunto de validación se encuentra, la figura dividida en tres partes (desplazamiento (a), voltaje (b), y fuerza (c)).




FIGURA 6.11: SEGUNDO CONJUNTO DE SEÑALES PARA LA VALIDACIÓN.

Se debe comparar los voltajes predichos por la red neuronal de cada uno de los dos conjuntos de validación con los voltajes deseados, tal y como se realizó anteriormente, para comprobar que la red neuronal es lo suficientemente óptima.

Par el primer conjunto de entrenamiento el valor del voltaje estimado por la red neuronal puede verse en la siguiente figura 6.12.




FIGURA 6.12: VOLTAJE PREDICHO POR LA RED PARA EL PRIMER CONJUNTO DE VALIDACIÓN.

Como puede verse la comparación entre la figura 6.12 y la figura 6.10 (observando el gráfico del voltaje (b)), se puede afirmar que la tensión predicha por la

red y la deseada son prácticamente iguales, lo que implica que el error que se comete con el primer conjunto de validación es muy reducido.

En la figura 6.13 se aprecia el voltaje estimado por la red, para el segundo conjunto de datos de validación.




FIGURA 6.13. VOLTAJE PREDICHO POR LA RED PARA EL SEGUNDO CONJUNTO DE VALIDACIÓN.

Al igual que en el caso anterior, otra vez la tensión estimada y la deseada vuelven a ser idénticas comparando la figura 6.13 con la figura 6.11 (ver figura 6.11, gráfico del voltaje (b)). El cálculo de los errores normalizados para los dos conjuntos de validación, dan unos resultados de 0.0018 y 0.002 para el primer y el segundo conjunto de validación respectivamente.

Puede afirmarse que la tecnología OBS es un éxito en el modelado de amortiguadores MR inversos [25].

CAPÍTULO 7: REDES NEURONALES ARTIFICIALES

7.1 INTRODUCCIÓN

Las redes neuronales es un modelo artificial basado en el comportamiento del cerebro humano. Este modelo tiene como objetivo la obtención de un determinado resultado a partir del entrenamiento de la red neuronal. La red neuronal consiste en un conjunto de neuronas, situadas en diferentes capas e interconectadas entre sí, para proporcionar una salida ante una serie de estímulos.

El funcionamiento de las redes neuronales consiste en lo siguiente: Cada neurona recibe una serie de señales de todas las neuronas a las que se encuentra conectada, y esta neurona procesa dichas señales y emite una salida, a otras neuronas a las que se encuentra conectada, produciéndose esto mismo, en todas las neuronas que componen la red y dando lugar a la salida deseada.

Los primeros modelos de redes neuronales fueron creados en 1943. Más tarde, en 1949 se desarrolló el aprendizaje neuronal dando lugar a lo que conocemos hoy en día como la regla de Hebb. En 1958 se desarrolló el perceptrón simple, y por último se dio lugar al Adeline, que supuso la primera aplicación de las redes neuronales al ámbito industrial. Los años posteriores a estas investigaciones surgieron un declive debido a la falta de modelos de aprendizaje, por lo que hasta los años 80 no se reanudó la investigación de las redes neuronales, debido al algoritmo de retropropagación desarrollado por en 1986, que posteriormente se aplicó en los perceptrón multicapa.

En este Trabajo de Fin de Grado se ha empleado para un modelo inverso de amortiguador MR, ya que este atiende a una función no lineal, el modelo de redes neuronales multicapa.

7.2 PERCEPTRÓN MULTICAPA

Las redes neuronales multicapa, como su propio nombre indica, están formadas por varias capas de neuronas, esto permite resolver problemas no linealmente separables. Este tipo de redes neuronales puede estar parcialmente conectado o totalmente conectado. En el caso de que se encuentren totalmente conectado, que es el caso de nuestra aplicación, ocurre lo siguiente en cada una de las neuronas que conforman la red.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

Cada salida de una neurona de una capa “i” es entrada de todas las neuronas de la capa “i+1”. Tal y como se muestra en la figura 7.1 a una neurona de cada capa le corresponde más de una entrada, por lo que las neuronas ponderan dichas entradas, multiplicando cada una de estas por un peso determinado, dando lugar a una salida. La arquitectura de este tipo de redes neuronales es la siguiente:

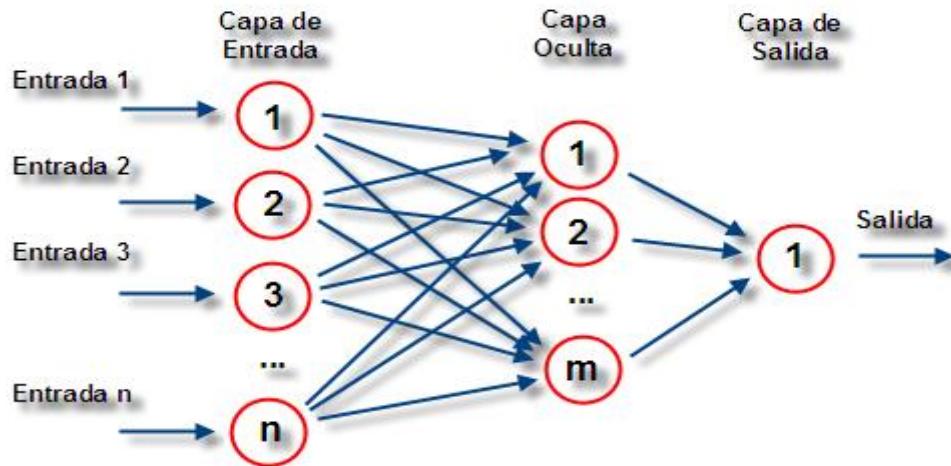


FIGURA 7.1: ESTRUCTURA RED NEURONAL ARTIFICIAL.

Atendiendo a la figura 7.1, esta está compuesta por diferentes capas, cada una de ellas tiene una serie de funciones y consiste en lo siguiente:

- **Capa de entrada:** Esta capa está constituida por el conjunto de neuronas que reciben las señales o patrones de entrada. En dichas neuronas no se produce procesamiento de información, es decir, son las entradas de la red.
- **Capa oculta:** Formada por las neuronas cuyas entradas proceden de las capas anteriores, procesan la información y su salida es la entrada de la siguiente capa. Puede estar formada por varias capas, aumentando estas, normalmente aumenta el rendimiento de la red. Con dos o tres capas ocultas es suficiente para obtener un correcto rendimiento de la red.
- **Capa de salida:** Reciben como entrada la salida de otras neuronas, típicamente suele ser la salida de las neuronas de la capa oculta. La salida de este tipo de neuronas es la salida de toda la red neuronal.

Como puede verse en la figura 7.1 este tipo de redes neuronales puede adquirir una mayor complejidad ya sea aumentando el número de capas tanto de entrada, de salida o de capa oculta.

Puede aumentarse el número de neuronas que conforman cada una de las capas. En resumen, la arquitectura de la red, es uno de los aspectos más complejos en el

entrenamiento de las redes neuronales, y el objetivo de este documento es conseguir una óptima red neuronal para el modelado de un amortiguador MR.

Una vez definida la estructura de la red neuronal, es necesario explicar el funcionamiento de cada una de las neuronas, y que procesamiento tiene lugar en el “interior” de cada una de ellas.

Cuando se emplea un programa de redes neuronales como puede ser el Javanns, las neuronas de cada una de las capas, necesitan una función de activación para poder funcionar correctamente.

7.3 FUNCIÓN DE ACTIVACIÓN

La función de activación de una neurona define la salida de dicha neurona dada una entrada o un conjunto de entradas determinadas. Esta se emplea para limitar el rango de valores de la salida de la neurona. Típicamente estos valores se limitan a (0,1) o (-1,1), aunque también otros rangos son posibles en función de la aplicación. Existen numerosas funciones de activación, en las que se empleará unas u otras en función del problema a resolver. En la figura 7.2 se muestra cómo opera dicha función.

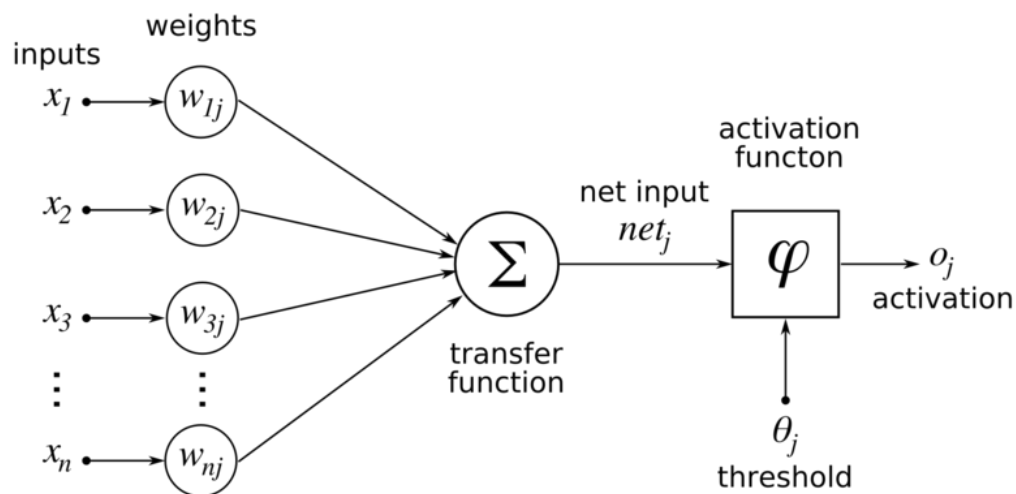


FIGURA 7.2: ESQUEMA FUNCIONAMIENTO DE UNA NEURONA, FUNCIÓN DE ACTIVACIÓN.

Las funciones de activación en una red neuronal de retropropagación (“backpropagation”) debe cumplir varias aspectos entre las que son:

1. Debe ser continua.
2. Debe ser diferenciable en cada uno de sus puntos.
3. Debe ser monótona no decreciente

Existen un gran número de funciones de activación, pero las más empleadas son las que se describen a continuación [26].

- **Función lineal:** Es una de las funciones más empleadas en redes neuronales. La función de activación lineal es la más útil y la más empleada en la capa de salida

de una red neuronal. Debido a que esta función sigmoide tiene una derivada de valor uno, es solo válida para la capa de salida. Este tipo de función atiende a la siguiente ecuación:

$$f(x) = x \quad (7.1)$$

En la figura 7.3 se muestra la curva de la función lineal.




FIGURA 7.3: FUNCIÓN LINEAL.

- **Función escalón:** La función de activación escalón o signo, puede tomar dos valores, el valor cero si las entradas toman un valor negativo, o valor uno si dichas entradas son positivas. Esta función ha dejado de emplearse ya que no cumple los aspectos mencionados con anterioridad, debido a que principalmente no es derivable en cero, ya que presenta un escalón. Su función es la siguiente

$$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (7.2)$$

En la figura 7.4 se muestra la curva de la función escalón.




FIGURA 7.4: FUNCIÓN ESCALÓN.

- **Función logística:** La función logística es una función real diferenciable y acotada, que se define para todos los valores de entradas reales y tiene derivada positiva en todos sus puntos. Es una función no lineal a diferencia de las anteriores y

cumple los tres objetivos marcados anteriormente (continua, diferenciable en todos sus puntos, y monótona creciente). Este tipo de función atiende a la siguiente ecuación.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (7.3)$$

En la figura 7.5 se muestra la curva de la función logística.




FIGURA 7.5: FUNCIÓN LOGÍSTICA.

- **Función tangente hiperbólica.** Es la versión continua de la función signo, ya que se encuentra acotada entre -1 y 1 a diferencia de la función logística. Es monótona creciente y derivable en todos sus puntos. Su función es la siguiente:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (7.4)$$




FIGURA 7.6: FUNCIÓN TANGENTE HIPERBÓLICA.

7.4 FUNCIÓN DE SALIDA

La función de salida es la que convierte el estado de la neurona en la salida hacia otras neuronas adyacentes. Normalmente suele emplearse como función de salida, la

función de activación, pero para poder describir el funcionamiento de esta es necesario conocer en qué consiste el estado de activación de una neurona.

Cada neurona recibe una serie de estímulos en forma vectorial $(x_1, x_2 \dots x_n)$, cada uno de estos son multiplicados por los pesos sinápticos de la dendrita, y luego se suman, como puede verse en la figura 7.7 [27].




FIGURA 7.7: SUMATORIO DE ENTRADAS POR LOS PESOS SINÁPTICOS.

El valor del sumatorio es lo que se considera como el estímulo de la neurona. Posteriormente este estímulo es procesado en el núcleo de la neurona mediante la siguiente operación:

$$\left[\sum_{j=1}^m w_j x_j + b \right] \varphi = \varphi(X^T W + b) = Y_i \quad (7.5)$$

Donde:

- w_j es el peso correspondiente a la entrada j .
- x_j es la entrada número j de la red neuronal.
- φ es la función de activación.
- b es el parámetro de sesgo o bias.
- Y_i es el estado de activación o respuesta del sistema a los estímulos percibidos.

La ecuación 7.5 se considera como la respuesta de la neurona al estímulo recibido. También puede considerarse como el estado de activación.

Si consideramos que la función de salida (γ_i) es igual al estado de activación (Y_i) (ver figura 7.8), es decir, la función identidad, se cumple lo siguiente:

$$\gamma_i = Y_i \quad (7.6)$$




FIGURA 7.8: FUNCIÓN DE SALIDA

7.5 PESOS SINÁPTICOS

Los pesos sinápticos son los que sirven para guardar todo el conocimiento adquirido durante el proceso de aprendizaje de la red neuronal.

Este proceso de aprendizaje puede ser dividido en paradigmas de aprendizaje y algoritmos de entrenamiento [27].

A continuación se describen los diferentes tipos de aprendizaje:

7.5.1 APRENDIZAJE SUPERVISADO.

Las redes neuronales de entrenamiento supervisado han sido los modelos de redes más empleados. Los datos de entrenamiento están formados por varios patrones de entrada y de salida. Se le denomina supervisado ya que al conocer la salida, el entrenamiento se ve beneficiado. En la figura 7.9 se muestra un esquema de este tipo de aprendizaje.




FIGURA 7.9: APRENDIZAJE SUPERVISADO.

A continuación se enumeran los diferentes tipos de aprendizaje supervisado:

- **APRENDIZAJE POR CORRECCIÓN DEL ERROR.** Dentro del aprendizaje supervisado, se encuentra el aprendizaje por corrección del error, que ajusta los pesos de las conexiones de la red, a partir de la diferencia obtenida entre los valores deseados y los valores obtenidos por la red neuronal durante su entrenamiento. (Ver figura 7.10).




FIGURA 7.10: ESQUEMA DE FUNCIONAMIENTO DE UN APRENDIZAJE POR CORRECCIÓN DEL ERROR.

Como puede apreciarse en la figura 7.10 Y_k representa la salida obtenida por la red neuronal en el proceso de entrenamiento, pero esta salida debe ser comparada con la entrada, y calcular el error para poder minimizarlo. Durante el entrenamiento de la red, lo que se realiza es el reajuste de los pesos, por lo que el peso siguiente se calculará teniendo en cuenta el error cometido anteriormente [27].

$$w_{kj}(n+1) = w_{kj}(n) + \alpha e_k(n) x_j(n) \quad (7.7)$$

Donde:

- $w_{kj}(n+1)$ es el correspondiente a la neurona $n+1$.
 - $w_{kj}(n)$ es el peso correspondiente a la neurona n .
 - α constante de aprendizaje.
 - $e_k(n) = d_k - Y_k$, es el error cometido.
 - d_k es el valor de la salida deseada.
 - Y_k es el valor de la salida obtenida por la red neuronal.
 - $x_j(n)$ es el valor de la entrada j para la neurona n .
- **ALGORITMO LMS (LEAST MEAN SQUARE).** El algoritmo LMS consiste en entrenar la red hasta que esta alcance un determinado valor del error cuadrático. Este es un algoritmo rápido que minimiza el MSE. El MSE es el promedio de la suma ponderada del error para un cierto conjunto de entrenamiento N , que se define mediante la ecuación 7.4.

$$MSE = \frac{\sum_{j=1}^N (R - C_j)^2}{N} \quad (7.8)$$

Donde:

- R es la salida deseada.
- C_j es la salida obtenida mediante el entrenamiento la red neuronal.
- N es el conjunto de entrenamiento.
- **APRENDIZAJE POR REFUERZO.** En el aprendizaje por refuerzo no se tiene información suficiente sobre la salida deseada, es decir, en este tipo de aprendizaje no muestra que salidas son correctas y cuáles no. Se basa en la idea de que el sistema pueda rastrear o explorar el entorno y pueda observar ciertas acciones, de las que se pueda obtener alguna información para el correcto aprendizaje de la red [28].
- **APRENDIZAJE ESTOCÁSTICO.** La principal función del aprendizaje estocástico es la de cambiar de manera aleatoria los valores de los pesos y evaluar su efecto a partir del objetivo deseado y de una serie de distribuciones de probabilidad. Una red que utiliza este tipo de aprendizaje es la red Boltzman Machine, inventada por Hinton, Ackley y Sejnowsky en 1984 y la red Cauchy Machine ideada por Szu en 1986 [28].

7.5.2 APRENDIZAJE NO SUPERVISADO.

El aprendizaje no supervisado no requiere de un "maestro" o "supervisor" para el ajuste de los pesos de las neuronas. La red no percibe ninguna señal que le informe que la salida que está generando a una determinada entrada es correcta o no, si no que son capaces de autosupervisarse. En realidad existen varias interpretaciones en las salidas que nos genera la red con este tipo de aprendizaje, que son:

- La salida representa el grado de similitud entre la información de entrada y las informaciones obtenidas anteriormente.
- Establecimiento de categoría, indicando la red a la salida a qué categoría pertenece la información de entrada, siendo la red la que debe establecer las correlaciones oportunas.

A continuación se enumeran los diferentes aprendizajes no supervisados:

- **APRENDIZAJE HEBBIANO.** El aprendizaje hebbiano obtiene información sobre de los datos de entrada, extrayendo una serie de características. Consiste en el ajuste de los pesos de las conexiones de acuerdo con la correlación de los valores de activación de las dos neuronas conectadas:

$$Incr(w_{ij}) = y_i y_j \quad (7.9)$$

Por lo tanto, este aprendizaje se basa en el estado de activación de las neuronas, es decir, si ambas se encuentran en el mismo estado, o activas o inactivas, la conexión entre ellas se ve reforzada, mientras que si una se encuentra activa y la otra inactiva, dicha conexión se verá mermada. Estas neuronas son binarias por lo que las entradas a estas neuronas son (0,1) o (-1,1).

- **APRENDIZAJE COMPETITIVO Y COOPERATIVO.** En el aprendizaje competitivo y cooperativo las neuronas compiten unas con otras con el fin de llevar a cabo una determinada tarea. Se quiere conseguir que cuando llegue una determinada información a la red, sólo una o grupo de ellas se activen. Por lo tanto las neuronas compiten entre ellas para activarse, quedando las desactivadas a valores de respuesta mínimos. La conexión entre las neuronas se realiza entre todas las capas de la red, siendo estas conexiones recurrentes de autoexcitación y conexiones de inhibición.

El objetivo del aprendizaje competitivo y cooperativo es poder clasificar o categorizar los datos que entran en la red. Por lo tanto, las informaciones que presenten cierta similitud se clasifican formando parte de la misma categoría, activando la misma neurona de salida.

Un ejemplo de este tipo de aprendizaje es el desarrollado por Kohonen como Learning Vector Quantization (LVQ) [28].

7.6 ASOCIACIÓN ENTRE LAS INFORMACIONES DE ENTRADA Y DE SALIDA.

Las redes neuronales son sistemas que almacenan cierta información aprendida, esta se queda guardada o registrada en los pesos asociados a las conexiones entre las neuronas. Debe establecerse una relación entre los datos que se presentan a la red y la salida aportada por esta. Esto es lo que se denomina memoria asociativa.

A continuación se enumeran los dos tipos de redes en función de la asociación de información entre la entrada y la salida [28]:

- **REDES HETEROASOCIATIVAS.** Las redes heteroasociativas aprenden parejas de datos $[(X_1, Y_1), (X_2, Y_2) \dots \dots \dots, (X_n, Y_n)]$, de manera que cuando a la red entre una determinada información X_i responda con la salida correspondiente Y_i . Como se asocian información de entrada con información de salida, la arquitectura de la red neuronal necesita al menos dos capas, una para captar y para guardar las informaciones de entrada y otra para mantener la salida con la información correspondiente de entrada, de no ser así, se perdería la información inicial al obtenerse la salida asociada. El aprendizaje de este tipo de redes puede ser con supervisión.

- **REDES AUTOASOCIATIVAS.** Las redes auto-asociativas aprenden ciertas informaciones ($X_1, X_2 \dots X_n$), de tal manera que se le presente una cierta entrada realizará una cierta autocorrelación, respondiendo a esa información de entrada con uno de los datos almacenados previamente, el más parecido al valor de la entrada. Para este tipo de redes es suficiente con una sola capa de neuronas. El tipo de aprendizaje empleado en este tipo de redes es normalmente el no supervisado.

7.7 REPRESENTACIÓN DE LA INFORMACIÓN DE ENTRADA Y SALIDA.

En la representación de la información de entrada y de salida se distinguen tres tipos de redes, que son [28]:

- **REDES CONTÍNUAS.** Este tipo de redes son la mayoría de redes, debido a que el conjunto de datos tanto de entrada como de salida son analógicos, es decir, que son valores reales continuos y típicamente normalizados. En este tipo de redes las funciones de activación deben ser continuas y del tipo lineal o tangente hiperbólica, tal como se empleará más adelante.
- **REDES DISCRETAS.** Este tipo de redes solamente admiten valores discretos (0,1) a la entrada, dando lugar en la salida respuestas del mismo tipo. En este caso la función de activación no tiene porque ser continua, por lo que la función escalón es totalmente válida.
- **REDES HÍBRIDAS.** Para el caso de redes híbridas, la información de entrada es continua pero en cambio su salida es binaria (0,1).

CAPÍTULO 8: ALGORITMO DE APRENDIZAJE “BACKPROPAGATION”

8.1 INTRODUCCIÓN.

Una red “Backpropagation” está conformada por “n” neuronas de entrada, al menos una capa oculta, y “m” neuronas de salida. “Backpropagation” proviene del inglés y significa la propagación hacia atrás de los errores o retropropagación, es un algoritmo de aprendizaje tipo supervisado muy empleado en el entrenamiento de las redes neuronales. Este algoritmo consiste en un ciclo de propagación-adaptación que consta de dos etapas. Cuando se le aplica a la red un patrón de entrada generándole un estímulo, este se propaga desde las capas de entrada hacia las sucesivas capas hasta que genera una determinada salida. Esta señal de salida es comparada con la deseada y por tanto se calcula una señal de error para cada una de las salidas generadas por la red. Estas señales de error, se propagan hacia atrás (segunda etapa), partiendo de la capa de salida, hacia todas las neuronas que conforman capa oculta que contribuyen directamente con la salida. Sin embargo, las neuronas de la capa oculta no reciben la señal de error completamente, si no una fracción de la misma, basándose aproximadamente en la aportación de cada neurona de la capa oculta a la señal de salida. Este proceso se repite capa por capa hasta que todas las neuronas que conforman el conjunto de la arquitectura de la red hayan recibido la señal de error que describa su contribución relativa al error total.

El principal objetivo de este tipo de aprendizaje consiste en que a medida que se va entrenando la red las neuronas de las capas intermedias se organizan entre sí, de tal manera que las neuronas aprendan a reconocer distintas características de los datos de entrada, por lo que, después del entrenamiento cuando a la red se le presente un patrón de entrada cualquiera las neuronas de la capa oculta responderán con una salida activa si el patrón de entrada desconocido se asemeja a aquella característica que las neuronas han aprendido durante su entrenamiento.

Por tanto este tipo de aprendizaje va a ser el empleado en el modelo inverso de amortiguador MR, ya que el objetivo es hacer aprender a la red mediante un conjunto de patrones de entrenamiento con el objetivo de que ante cualquier patrón desconocido la red aporte la señal de salida deseada [29].

8.2 REGLA DE APRENDIZAJE DEL ALGORITMO "BACKPROPAGATION".

La regla de aprendizaje "backpropagation" funciona como ya se ha mencionado anteriormente (en la introducción del capítulo) con un aprendizaje supervisado y por tanto necesita un conjunto de entrenamiento que describa cada salida y su valor de salida deseado, esto se muestra en la ecuación 8.1:

$$(P_1, Q_1), (P_2, Q_2) \dots (P_n, Q_n) \quad (8.1)$$

Donde P_n es una entrada a la red y Q_n es la salida deseada para el patrón n -ésimo. El principal objetivo de este algoritmo de aprendizaje es el reajuste de los parámetros de la red, con el objetivo de reducir el error medio cuadrático. Cabe destacar que no existe una "fórmula" que obtenga el número de capas ocultas y el número de neuronas de dicha capa que optimice la red neuronal por lo que el número de estas se obtiene experimentalmente y a partir de la experiencia del diseñador de la red durante la resolución de un problema específico. Cada patrón de entrenamiento se propaga a través de la red y sus parámetros para producir una respuesta en la capa de salida, que se compara con la salida deseada dando lugar a un error cuadrático en el aprendizaje, a partir de este error se actualizarán los pesos y ganancias que al final del entrenamiento producirán la salida óptima para cualquier patrón de entrenamiento.

Para iniciar el entrenamiento de la red neuronal necesitamos introducir un patrón de entrenamiento el cual se representa en forma vectorial en la ecuación 8.2:

$$p = \begin{pmatrix} p_1 \\ p_2 \\ \vdots \\ \vdots \\ \vdots \\ p_n \end{pmatrix} \quad (8.2)$$

Donde:

- p_i es la entrada correspondiente a una neurona de la capa de entrada, si el vector está formado por n componentes la capa de entrada estará formada por n neuronas de entrada, correspondiendo el subíndice de la componente del vector, con la posición de la neurona en la capa de entrada. El valor de p_2 es la entrada en la neurona 2 de la capa de entrada.

Cuando a la red se le presenta un patrón de entrenamiento como el de la ecuación 8.1, este se propaga a través de las conexiones que conforman la red

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

produciendo una entrada n en cada una de las neuronas de la siguiente capa. Por tanto, la entrada en la neurona j de la siguiente capa viene dada por ecuación 8.3:

$$n_j^0 = \sum_{i=1}^q (w_{ji}^0 * p_i) + b \quad (8.3)$$

Donde:

- w_{ji}^0 es el peso que una la componente i de la entrada con la neurona j de la capa oculta.
- p_i componente i del vector p que contiene el patrón de entrenamiento de q componentes.
- b ganancia o sesgo de la neurona j de la capa oculta.
- n_j^0 estímulo generado en la siguiente capa.

Donde (0) representa la capa a la que pertenece cada parámetro, que en este caso es la capa oculta. Una vez definido el estímulo que reciben las neuronas de la capa oculta mediante la ecuación 8.3, se definirá la salida que estas experimentarán ya sea para otra capa oculta (en el caso de varias capas ocultas) o hacia la capa de salida (en el caso de una única capa oculta). Cada una de las neuronas de la capa oculta tiene como salida a_j^0 , definida por:

$$a_j^0 = f^0 \left(\sum_{i=1}^q (w_{ji}^0 * p_i) + b_j^0 \right) \quad (8.4)$$

Donde:

- f^0 es la función de activación de las neuronas de la capa oculta.

Las salidas a_j^0 de las neuronas de la capa oculta (de m componentes) son las entradas a los pesos de conexión de la capa de salida (en este caso solo se dispone de una capa oculta), la cual cuenta con s neuronas. La salida en la capa oculta es igual a a_j^0 debido a que la función de salida en este tipo de aprendizajes es la función identidad, por lo que la salida de las neuronas va a ser el estado de activación, es decir, en el caso de la capa oculta a_j^0 .

Por tanto, el estímulo generado en la capa de salida es:

$$n_k^s = \sum_{j=1}^m (w_{kj}^s * a_j^0) + b_k^s \quad (8.5)$$

Donde:

- w_{kj}^s es el peso que une la neurona j de la capa oculta con la neurona k de la capa de salida, la cual está formada por s neuronas.
- a_j^0 es la salida de la neurona j de la capa oculta, que cuenta con m neuronas.
- b_k^s ganancia de la neurona k en la capa de salida.

Por tanto, el estado de activación de la capa de salida es:

$$a_k^s = f^s \left(\sum_{j=1}^m (w_{kj}^s * a_j^0) + b_k^s \right) \quad (8.6)$$

Donde:

- f^s es la función de activación de la capa de salida.

Tal y como se menciona anteriormente, una vez obtenido el estado de activación de la neurona y sabiendo que la función de salida en todas las neuronas es la función identidad, la salida de las neuronas de la capa de salida es a_k^s .

Una vez obtenida la salida proporcionada por la red neuronal debemos comparar esta con la deseada y estimar el error correspondiente. El valor de a_k^s debe compararse con la salida deseada que es t_k y calcular el error de cada una de las neuronas de salida.

La diferencia entre la obtenida y la deseada se estima de la siguiente forma:

$$\delta_k = (t_k - a_k^s) \quad (8.7)$$

Por tanto el error que comete cada patrón p es:

$$ep^2 = \frac{1}{2} \sum_{k=1}^s (\delta_k)^2 \quad (8.8)$$

Donde:

- ep^2 es el error cuadrático medio para cada patrón p .
- δ_k es error en la neurona k de la capa de salida.

Este proceso se repite continuamente para el conjunto de patrones de entrenamiento (r), el principal objetivo de este aprendizaje para obtener los resultados deseados es el de actualizar todos los pesos y ganancias de la red reduciendo el error cuadrático medio total.

El error cuadrático medio total de la red neuronal es:

$$e^2 = \sum_{p=1}^r ep^2 \quad (8.9)$$

Donde:

- e^2 es el error total en el proceso de aprendizaje.

Por lo tanto, el principal objetivo es entrenar la red neuronal mediante un conjunto de patrones de entrenamiento y de validación, con el objetivo de que la red, reajuste los pesos y las ganancias para minimizar el error total e^2 .

Como puede verse en las ecuaciones anteriores, el error es función de los pesos de la red, este genera un espacio de n dimensiones, donde n es el número de pesos que tiene la red. Para minimizar el error, es necesario calcular el gradiente del error en un punto del espacio generado por el conjunto de pesos, con este gradiente se obtendrá la dirección en la cual la función del error experimentará su mayor crecimiento. Como el objetivo del aprendizaje es minimizar el error debe tomarse la dirección negativa del gradiente para obtener el mayor decremento del error cuadrático y de esta forma su minimización, condición requerida para realizar la actualización de la matriz de pesos en el algoritmo “backpropagation” [30]:

$$W_{k+1} = W_k - \alpha \nabla ep^2 \quad (8.10)$$

Donde:

$$-\nabla ep^2 = -\frac{\partial ep^2}{\partial W_{kj}^s} = (t_k - a_k^s) * \frac{\partial a_k^s}{\partial W_{kj}^s} \quad (8.11)$$

- α es el ratio o factor de aprendizaje, que varía en función de las características del problema a solucionar.
- W_k peso de la capa de salida.
- W_{k+1} peso actualizado de la capa de salida.

Por tanto, una vez calculado el valor del gradiente del error, se procede a actualizar los pesos de todas las capas empezando por la de salida, para la capa de salida la actualización de pesos y ganancias viene dadas por las ecuaciones 8.11 y 8.12.

$$W_{kj}(t+1) = W_{kj}(t) - 2\alpha\delta_k^s \quad (8.12)$$

$$b_k(t+1) = b_k(t) - 2\alpha\delta_k^s \quad (8.13)$$

Sabiendo que:

$$\delta_k^s = (t_k - a_k^s)f'^s(n_k^s) \quad (8.14)$$

Donde:

- f'^s es la derivada de la función de activación, de la ecuación 8.14 se obtiene que la función de activación debe ser continua y derivable, para que δ_k^s tenga un valor real, y puedan actualizarse los pesos de la red neuronal.

Una vez actualizados los pesos de la capa de salida, debe hacerse lo mismo con los pesos y las ganancias de la capa oculta mediante las ecuaciones 8.15 y 8.16.

$$W_{ji}(t+1) = W_{ji}(t) - 2\alpha\delta_j^0 p_i \quad (8.15)$$

$$b_{ji}(t+1) = b_{ji}(t) - 2\alpha\delta_j^0 \quad (8.16)$$

Sabiendo que:

$$\delta_j^0 = f'^o(n_j^o) * \sum_{k=1}^l \delta_k^s W_{kj}^s \quad (8.17)$$

Todas estas deducciones fueron realizadas para una topología de red de tres capas (una de entrada, una capa oculta y una capa de salida). Si se quiere realizar el análisis para una red con dos o más capas ocultas las expresiones se derivan de la ecuación 8.17, donde los términos que aparecen dentro del sumatorio pertenecen a la capa inmediatamente superior, aumentándose el número de sumatorios con el número de capas ocultas.

En las técnicas de gradiente descendiente es muy conveniente avanzar por la superficie del error con incrementos pequeños de los pesos, esto se debe a que cuando se tiene una cierta información local sobre la superficie del error, y no se sabe lo lejos o lo cerca que se encuentra del punto de error mínimo, con incrementos grandes se corre el riesgo de pasar por el punto mínimo, por lo que si los incrementos son pequeños, aunque se tarde más en llegar al punto mínimo de error, evitamos pasarnos dicho punto. La elección de un adecuado incremento influye en la velocidad de convergencia de un algoritmo, esta velocidad se controla a través del ratio de aprendizaje (α), por lo que generalmente se escoge un valor pequeño de este, para asegurarse de que la red encuentre la solución. Si se escoge un valor pequeño significa que la red tendrá que realizar un gran número de iteraciones, sin embargo si escoge un valor elevado, los

cambios en los pesos serán muy grandes, avanzando muy rápidamente por la superficie de error con el riesgo de saltarse el punto mínimo del error y estar oscilando alrededor de él sin poder alcanzarlo [30].

Algo importante que debe destacarse durante el entrenamiento de la red, es la posibilidad de que el error converja hacia alguno de los mínimos locales que pueden existir en la superficie del error del espacio de pesos sinápticos, un ejemplo de la superficie generada puede verse en la figura 8.1.

En el desarrollo matemático para caracterizar el algoritmo “backpropagation”, no se asegura que el mínimo que se encuentre sea global, una vez que la red se encuentre en un mínimo ya sea local o global cesa el aprendizaje de la red, aunque el error tengo un valor elevado. En caso de que ocurra esto, debe estimarse si el error obtenido es aceptable o no, en caso de ser aceptable no es importante si el mínimo es local o global o si se ha detenido en algún momento anterior [30].




FIGURA 8.1: GRÁFICO DE LA SUPERFICIE DEL ERROR.

Este proceso de aprendizaje se empleará en una red neuronal multicapa para un modelo inverso de amortiguador MR. El principal objetivo es entrenar la red neuronal, y una vez entrenada poder implementarla en un vehículo con suspensión semi-activa, mediante unos sensores situados estratégicamente que alimenten a un controlador, el cual informa al modelo inverso con la fuerza que se debe ejercer en el amortiguador. Con esta fuerza el modelo inverso generará la intensidad deseada en el amortiguador MR para ejercer la fuerza indicada por el controlador.

El proceso de entrenamiento, se describe en el siguiente capítulo, donde puede observarse, que no es una tarea fácil y donde el obtener un buen resultado durante el entrenamiento depende de numerosos parámetros, como por ejemplo el ratio de aprendizaje, número de capas ocultas, número de neuronas en cada capa, etc.

CAPÍTULO 9: DATOS EXPERIMENTALES EN ENTRENAMIENTO DE RED MULTICAPA

9.1 INTRODUCCIÓN.

Antes de comenzar el entrenamiento de las diferentes redes neuronales, es necesario tomar una serie de medidas experimentales para poder elaborar el conjunto de patrones de entrenamiento y de validación, con el objetivo de entrenar a la red correctamente. Las pruebas se han realizado en un amortiguador MR que se encuentra en el laboratorio de la universidad y cuyo modelo pertenece a la casa de automoción audi, al modelo audi TT 2011.

Para poder tomar las medidas, es necesario instalar dicho dispositivo en un banco de pruebas o de ensayos, donde se instala el amortiguador a estudio, el cual es conectado mediante una interfaz a un ordenador donde se controla todos los aspectos necesarios, como pueden ser fuerza, desplazamiento, frecuencia, etc. Dichos datos son obtenidos en el ordenador y tratados para obtener un amplio conjunto de datos para el entrenamiento.

En la figura 9.1, puede verse el banco de pruebas que alberga el amortiguador en su interior.



FIGURA 9.1: BANCO DE PRUEBAS AMORTIGUADOR MR.

De este banco de pruebas se obtuvo un fichero Excel en el que se guardaron los valores de desplazamiento, velocidad, fuerza, frecuencia e intensidad de corriente deseada. Este fichero contiene 179811 filas, con sus correspondientes columnas para cada uno de los valores citados anteriormente, por lo que se obtiene un conjunto de 899055 datos.

Ante esta gran cantidad de datos es necesario hacer una selección para elaborar el conjunto de patrones de entrenamiento y validación.

9.2 CONJUNTO DE PATRONES DE ENTRENAMIENTO Y VALIDACIÓN.

En este Trabajo de Fin de Grado se trata de conseguir un modelo inverso de un amortiguador MR. Las entradas o los estímulos empleados para entrenar a la red son, el desplazamiento, la velocidad, la fuerza y la frecuencia, la salida será la intensidad deseada. Las pruebas se realizaron para diferentes valores de intensidad (0, 0.2, 0.4, 0.6, 0.8 Amperios).

Para obtener el modelo inverso se empleará un programa de redes neuronales, empleando un aprendizaje tipo supervisado, es decir, el aprendizaje “backpropagation”, para el que es necesario crear un conjunto de patrones de entrenamiento y validación, tal y como se indicó en la introducción.

Debido al gran volumen de datos, para generar los patrones de entrenamiento se seleccionó 2691 patrones, teniendo en cuenta que entre este conjunto de valores tienen que albergar todas las diferentes intensidades y las diferentes frecuencias que oscilan de 0.5 en 0.5 Hz hasta 9 Hz. Esto es necesario realizarlo ya que si no se estaría cometiendo un error importante.

Para el entrenamiento de la red neuronal, se emplea el programa Javanns por lo que para que este programa pueda entrenar la red neuronal con el conjunto de patrones de entrenamiento deseados, es necesario generar un archivo de texto en el cual debe figurar en la cabecera el conjunto de patrones de entrenamiento, el número de unidades de entrada y el número de unidades de salida, y guardarlo como archivo .pat. En este documento cada patrón de entrenamiento está formado por cinco valores, los 4 valores de entrada y el valor de salida deseada en la red neuronal. Es necesario que exista separación entre cada uno de los valores en los patrones de entrenamiento. Un ejemplo de cómo generar este tipo de archivos se puede apreciar en la figura 9.2.

De estos 2691 patrones, para el conjunto de entrenamiento, se seleccionó un patrón de validación de cada 10 patrones de entrenamiento, debido a que el conjunto de patrones de validación no debe tener el mismo volumen de datos, si no un valor más reducido.

Por lo tanto, el conjunto de datos de validación es de 265 patrones (ver figura 9.3), en el que se emplea el mismo procedimiento que para el conjunto de

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

entrenamiento, es decir, se generan los patrones en un archivo de texto, se guardan como un archivo .pat.

En la figura 9.3 puede verse el conjunto de validación, por supuesto, no en su totalidad ya que es muy difícil plasmar 265 patrones en una imagen.

```
No. of patterns : 2691
No. of input units : 4
No. of output units : 1

-1.18932      0      -0.00003 0.5 0
-1.25375     -0.00001  -0.00012 0.5 0
-1.27636     -0.000033  -0.00036 0.5 0
-1.32464     -0.00011  -0.00081 0.5 0
-1.38584     -0.000264  -0.00159 0.5 0
-1.47611     -0.00055  -0.00276 0.5 0
-1.52133     -0.001001  -0.00435 0.5 0
-1.54377     -0.001672  -0.00645 0.5 0
-1.60191     -0.002607  -0.00906 0.5 0
-1.7017      -0.003817  -0.01215 0.5 0
-1.78228     -0.007139  -0.01983 0.5 0
-1.85317     -0.009262  -0.02433 0.5 0
-1.92406     -0.01166  -0.02922 0.5 0
-1.97251     -0.014333  -0.03447 0.5 0
-1.98866     -0.017226  -0.03999 0.5 0
-2.03048     -0.020317  -0.04575 0.5 0
-2.12398     -0.02354  -0.05166 0.5 0
-2.15934     -0.02684  -0.05769 0.5 0
-2.17549     -0.030151  -0.06372 0.5 0
-2.21748     -0.03344  -0.06969 0.5 0
-2.31727     -0.039666  -0.08112 0.5 0
-2.35603     -0.042504  -0.08646 0.5 0
-2.41077     -0.045111  -0.09144 0.5 0
-2.5075      -0.047465  -0.096 0.5 0
-2.56224     -0.049522  -0.10011 0.5 0
-2.54932     -0.051304  -0.10368 0.5 0
-2.601       -0.052811  -0.10674 0.5 0
-2.6911      -0.054032  -0.10926 0.5 0
-2.76845     -0.054967  -0.11121 0.5 0
-2.79429     -0.05566  -0.11265 0.5 0
```

FIGURA 9.2: CONJUNTO DE PATRONES DE ENTRENAMIENTO.

```
No. of patterns : 265
No. of input units : 4
No. of output units : 1

-3.35512     -0.05355  -0.10629 0.5 0
-4.75065     -0.049555  -0.10815 0.5 0
-5.51769     -0.050061  -0.10935 0.5 0
-6.47496     -0.048312  -0.11169 0.5 0
-7.26767     -0.047872  -0.10929 0.5 0
-8.24109     -0.045782  -0.11412 0.5 0
-8.24109     -0.045782  -0.11412 0.5 0
-9.56573     -0.042053  -0.11484 0.5 0
-10.54544    -0.04004  -0.11715 0.5 0
-11.78304    -0.035409  -0.11979 0.5 0
-12.64358    -0.03344  -0.12117 0.5 0
-14.00035    -0.025355  -0.12663 0.5 0
-15.06064    -0.018106  -0.12219 0.5 0
-15.9664     -0.004818  -0.10347 0.5 0
-15.46677    0.011429  -0.0264 0.5 0
-13.66511    0.024959  0.11703 0.5 0
-13.64913    0.025025  0.11739 0.5 0
-11.02569    0.036157  0.12606 0.5 0
-9.67521     0.040018  0.12276 0.5 0
-3.3422      0.04961  0.13557 0.5 0
2.39785      0.051579  0.14979 0.5 0
6.28456      0.048818  0.15879 0.5 0
11.05136     0.038445  0.16104 0.5 0
15.97269     0.004906  0.15522 0.5 0
14.89625     -0.016995  -0.06228 0.5 0
10.40026     -0.036861  -0.08211 0.5 0
5.09218      -0.049588  -0.09762 0.5 0
-1.83396     -0.051689  -0.10536 0.5 0
-4.92796     0.095304  0.14949 1 0
```

FIGURA 9.3: CONJUNTO DE PATRONES DE VALIDACIÓN.

9.3 ARQUITECTURA Y ENTRENAMIENTO DE LA RED NEURONAL.

Una vez conocido, el tipo de aprendizaje establecido en la red y guardados los diferentes patrones de entrenamiento y validación, el siguiente paso es generar la arquitectura de la red.

La arquitectura de la red constará de cuatro entradas, las cuales pertenecerán como ya se ha comentado, a desplazamiento, fuerza, velocidad y frecuencia, y una salida, que es la intensidad que debemos aplicarle a la bobina instalada en el amortiguador MR, para general el campo magnético deseado. El problema reside en seleccionar cuantas capas ocultas, cuantas neuronas forman dichas capas y que ratio de aprendizaje se emplea, ya que este es de vital importancia para conseguir el mínimo error, tal y como se ha comentado en el capítulo 8. Por lo que el principal objetivo es seleccionar la red óptima que minimice el error cuadrático total de la red.

El diseño y selección de la red se realiza experimentalmente, probando con diferentes tipologías y diferentes ratios de aprendizaje con el objetivo de reducir el error y que la red aprenda los patrones correctamente.

9.3.1 RED NEURONAL CON UNA CAPA OCULTA Y 20 NEURONAS EN CADA CAPA OCULTA.

La experiencia y el entrenamiento de numerosas redes neuronales ha demostrado que a mayor número de capas ocultas mejor es el rendimiento de la red neuronal pero en este caso se ha comenzado con una tipología de una única capa oculta.

Los primeros pasos a seguir es crear la arquitectura de la red (ver figura 9.4). Una vez obtenida la red es necesario generar las conexiones de todas las neuronas de la red. El tipo de conexión que se emplea es “feedforward” cuyo significado es que las redes están conectadas hacia adelante, es decir, las salidas de las neuronas son las entradas de las siguientes capas.

Conociendo que las neuronas de entrada y de salida son constantes, el diseño reside en el número de capas ocultas y número de neuronas que forman estas capas.

El primer diseño consta de:

- Numero de capas ocultas: Una capa oculta.
- Neuronas en la capa oculta: 20 neuronas.
- Función de activación: Tangente hiperbólica. Al emplear un tipo de aprendizaje “Backpropagation” la función de activación debe ser continua, derivable y acotada entre -1 y 1.
- Función de salida: Función identidad.
- Función de aprendizaje: “Backpropagation”.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

Con la arquitectura de la red y todas las neuronas totalmente conectadas el siguiente paso es cargar los patrones de entrenamiento y de validación y ubicar cada patrón como es debido.




FIGURA 9.4: TOPOLOGÍA 4_20_1.

Antes de empezar el entrenamiento de la red es necesario y muy importante el inicializar el valor de los pesos de las conexiones para el correcto aprendizaje de la red.

Una vez inicializados los pesos, debemos entrenar a la red variando el ratio de aprendizaje que es el elemento encargado de alcanzar el error mínimo. La experiencia en el entrenamiento de redes neuronales conduce a comenzar entrenando la red con un ratio de aprendizaje de 0.2 y manteniendo este, siempre y cuando el error siga disminuyendo, y cuando el error permanezca constante, ir disminuyendo el ratio de aprendizaje.

En la tabla 1 se muestra los factores de aprendizaje para la red 4_20_1.

FACTOR DE APRENDIZAJE (η)	Nº DE CICLOS
0.2	50000
0.1	50000
0.01	50000
0.001	50000

TABLA 3: FACTORES DE APRENDIZAJE PARA 4_20_1

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

Una vez entrenada la red, con los parámetros indicados en la tabla 1, y insertando los patrones de entrenamiento en modo aleatorio (“shuffle”), y no en el mismo orden que en el archivo en el que fueron guardados con el objetivo de conseguir un mejor aprendizaje, se obtuvo el siguiente gráfico de error, (ver figura 9.5) que es a partir del cual se pueden obtener conclusiones del correcto entrenamiento de la red.




FIGURA 9.5: GRÁFICO DE ERROR RED 4_20_1.

Antes de comentar las conclusiones que se obtiene de la figura 9.5, es necesario mencionar que la curva en negro muestra el error que comete la red durante el entrenamiento, y la curva rosa, hace referencia al error de validación. Los dos errores deben tenerse muy en cuenta y aquella que tipología de red que presente los menores errores de validación y entrenamiento, será la empleada para el modelo inverso.

Como puede verse en la figura 9.5, el error que nos proporciona el programa, es el error cuadrático medio total explicado anteriormente en el capítulo 8. El error comienza en un valor muy elevado, y se estabiliza en torno a los 50000 ciclos, posteriormente al cambiar el ratio de aprendizaje de 0.2 a 0.1 este disminuye en torno a un error de $200 A^2$ (Amperios al cuadrado ya que se aporta el error cuadrático), con este error se entrena la red durante otros 50000 ciclos hasta observar que este permanece constante durante el entrenamiento, posteriormente se reduce el factor de aprendizaje a 0.1 y 0.01, pero el entrenamiento con estos factores de aprendizaje no puede apreciarse con claridad en la figura 9.5. Esto sucede muy a menudo y sobre todo cuando se comienza con un error tan elevado como el de este caso, para ello debe variarse la escala.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES




FIGURA 9.6: GRÁFICO DE ERROR 1 RED 4_20_1.

Tal y como se muestra en la figura 9.6, el error varía de entrenamiento varía poco entre 0.01 y 0.001. También cabe destacar el error de validación ha disminuido al igual que el error de entrenamiento. Es normal que el error de validación tenga un error menor que el de entrenamiento ya que tiene un menor número de patrones de entrenamiento. El error de entrenamiento sigue teniendo un valor muy alto, aunque nos encontremos con un modelo inverso, ya que típicamente los modelos inversos entrenan peor que los modelos directos.

El error de entrenamiento se encuentra en torno a $27 A^2$, lo que nos hace indicar que la intensidad proporcionada por la red, y la deseada presentan una gran diferencia, por lo tanto surgen dos aspectos importantes. En primer lugar puede afirmarse que la tipología de la red o su arquitectura no es la correcta y en segundo lugar, que los ratios de aprendizaje no se han variado debidamente.

Manteniendo la misma topología de red, se varía los ratios de aprendizaje. Como puede verse en la figura 9.6, cuando se aplica a la red un ratio de 0.01 el error de entrenamiento disminuye hasta $30 A^2$ y luego este reduce muy poco con 0.001, alcanzando un valor de $27 A^2$. Por lo tanto se comienza el entrenamiento de la red por un α de 0.01.

En la tabla 2 se muestra los ciclos y los factores de entrenamiento empleados.

FACTOR DE APRENDIZAJE (η)	Nº DE CICLOS
0.2	0
0.1	0
0.01	250000
0.001	100000

TABLA 4: FACTORES DE APRENDIZAJE 0.01 Y 0.001 PARA 4_20_1.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

Una vez entrenada la red, tal y como se indica en la tabla 2, se muestra en la figura 9.7 el gráfico de error (se visualiza el error de entrenamiento y de validación).




FIGURA 9.7: GRAFICO DE ERROR 2 RED 4_20_1.

El variar el ratio de aprendizaje y comenzar por 0.01 en lugar de 0.2, se tiene un resultado bastante óptimo al obtenido anteriormente comenzando por 0.2 y siguiendo por 0.1. El error cuadrático total de entrenamiento se encuentra inferior a $10 A^2$ en torno a un valor de $7 A^2$. Como el error es elevado, no se considera necesario poner decimales para una mayor exactitud. Cabe destacar que se aumenta el número de ciclos de entrenamiento con un α de 0.1 ya que su curva de error se encuentra descendiendo durante un gran número de ciclos y esta tarda en estabilizarse, esto es así, porque la red se encuentra recorriendo la superficie de error muy lentamente para poder encontrar el mínimo local o global. El ratio de aprendizaje 0.001 no produce un gran descenso del error, al igual que ocurría en el caso anterior, esto puede deberse a que es un ratio de aprendizaje demasiado bajo, y por tanto las actualizaciones de los pesos de la red no tienen la suficiente influencia en el error total.

El error de validación (curva rosa) al igual que en el caso anterior es muy reducido, adquiriendo un valor en torno a $1 A^2$.

En conclusión, el empezar por un ratio de aprendizaje de 0.01, entrenando un gran número de ciclos, parece una buena solución en la reducción del error. Pero con esta prueba no es suficiente, debe realizarse el mismo procedimiento con diferentes topologías y asegurarse de que este funciona, ya que no podríamos extenderlo a todas las tipologías sin tener un amplio muestreo de diferentes arquitecturas de red.

9.3.2 RED NEURONAL CON DOS CAPAS OCULTAS Y 20 NEURONAS EN CADA CAPA OCULTA.

Una vez que se ha demostrado que el error ha sido mejorado variando los ratios de aprendizaje, se va a modificar la arquitectura de la red, aumentando el número de

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

capas ocultas y manteniendo el número de neuronas en la capa oculta, es decir, 20 en cada una.

En la figura 9.8, puede verse la topología de la red con dos capas ocultas.




FIGURA 9.8: TOPOLOGÍA 4_20_20_1.

Para este tipo de topología de red se han mantenido los mismos parámetros y funciones que en el caso de una sola capa oculta, es decir:

- Numero de capas ocultas: 2 capas ocultas.
- Neuronas en la capa oculta: 20 neuronas.
- Función de activación: Tangente hiperbólica.
- Función de salida: Función identidad.
- Función de aprendizaje: "Backpropagation".

Al tener otra tipología de red, la variación de los ratios de entrenamiento se modifican según la tabla 3.

FACTOR DE APRENDIZAJE (η)	Nº DE CICLOS
0.2	13000
0.1	5000
0.01	50000
0.001	20000

TABLA 3: FACTORES DE APRENDIZAJE PARA 4_20_20_1.

El hecho de emplear 13000 ciclos con un factor de aprendizaje de 0.2 y 5000 ciclos con un factor de aprendizaje de 0.1, es debido a que en un entrenamiento previo,

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

se aprecia que a partir de estos números de ciclos con estos ratios de aprendizaje, la red neuronal comenzaba a desaprender y el error de entrenamiento aumentaba considerablemente. Por tanto, se fijaron estos ciclos y a partir de estos se comienza a variar el ratio de aprendizaje. Con los factores 0.01 y 0.001 se entrenó un mayor número de ciclos ya que la red no desaprendía, este hecho es normal, ya que tal y como se ha dicho anteriormente un ratio de aprendizaje reducido es más óptimo para alcanzar el error mínimo.

En la figura 9.9, se muestra el gráfico de error para los parámetros de la tabla 3.




FIGURA 9.9: GRÁFICO DE ERROR 3 RED 4_20_20_1.

Como puede apreciarse en la figura el error de entrenamiento ha disminuido considerablemente frente al obtenido en la red 4_20_1 para los mismos ratios de entrenamiento (0.2, 0.1, 0.01, 0.001). Puede sacarse la conclusión de que a medida que se aumenta el número de capas ocultas el error cometido por la red neuronal disminuye.

Cabe destacar, que el mayor descenso de error se produce para un factor de entrenamiento de 0.01, por lo que al igual que lo que ha ocurrido con la red 4_20_1, la red de dos capas a ocultas se entrena posteriormente comenzando con un ratio de 0.001.

Al igual que sucede en los casos anteriores es necesario variar la escala del gráfico de error para poder observar correctamente el error cometido por la red neuronal.

En la figura 9.10 pude verse con mayor exactitud el error cometido.




FIGURA 9.10: GRÁFICO DE ERROR 4 RED 4_20_20_1.

Observando la figura 9.10 puede obtenerse un error cuadrático total de entrenamiento de $8 A^2$ bastante más mejorado que el obtenido con una sola capa oculta. Este valor sigue siendo demasiado alto, por lo que es necesario seguir variando parámetros con el objetivo de reducir el error.

Como ya se ha sugerido anteriormente, y a pesar de lo que típicamente suele hacerse en el entrenamiento de las redes neuronales, se comienza entrenado por un ratio de aprendizaje de 0.01.

Manteniendo los mismos parámetros e inicializando de nuevos los pesos de las conexiones se empieza a entrenar a la red, tal y como se indica en la tabla 4.

FACTOR DE APRENDIZAJE (η)	Nº DE CICLOS
0.2	0
0.1	0
0.01	150000
0.001	100000

TABLA 4: FACTORES DE APRENDIZAJE 1 PARA 4_20_20_1.

En este caso se ha aumentado el número de ciclos de entrenamiento, ya que las curvas tardaban más en estabilizarse, sobre todo para el factor de aprendizaje de 0.01 (ver figura 9.11).

En la figura 9.11 puede verse el gráfico de error para este caso.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES




FIGURA 9.11: GRÁFICO DE ERROR 5 RED 4_20_20_1.

Puede verse en la figura 9.11 que el error se ha reducido en torno a $1 A^2$. En la figura 9.12 puede verse una ampliación y observar con mayor exactitud el error de entrenamiento cometido. Por tanto el entrenar a la red comenzando por un ratio bajo, en oposición a lo que normalmente se hace, puede dar buenos resultados.

Se sigue cumpliendo para una tipología de dos capas ocultas, lo ocurrido con una sola capa oculta. También hay que observar y razonar detenidamente, que al aumentar el número de capas ocultas y al empezar por un factor de aprendizaje reducido disminuye el error, por tanto puede ser esta una buena línea, y el aumento de capas ocultas y el comienzo de entrenamiento con una ratio de 0.01 puede llevar a una solución óptima.




FIGURA 22: GRAFICO DE ERROR 6 RED 4_20_20_1.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

9.3.3 RED NEURONAL CON TRES CAPAS OCULTAS Y 20 NEURONAS EN CADA CAPA OCULTA.

Aunque en los apartados anteriores se haya mostrado que aumentando el número de capas ocultas y empezando el entrenamiento por un factor de aprendizaje reducido ($\alpha=0.01$) disminuye el error de entrenamiento y validación, hay que destacar que cada tipología de red puede presentar un aprendizaje diferente, por lo tanto es aconsejable comenzar entrenando por un factor elevado ($\alpha=0.2$) e ir descendiendo este progresivamente cuando las curvas de error se estabilicen.

Antes de analizar los gráficos de errores, es importante mostrar cómo es la tipología de la red con tres capas ocultas, ya que su complejidad y su número de conexiones aumentan en valores muy altos, y por tanto el entrenamiento es más complejo y más tardío que en una tipología más simple, es decir, de menos capas ocultas.

Se está empleando 20 neuronas por cada capa oculta en todos los ejemplos de ensayos mostrados, más adelante se mostrará que sucede si además de variar el número de capas ocultas y el ratio de aprendizaje, se aumenta el número de neuronas en cada capa oculta.

En la figura 9.13 puede verse la topología con 3 capas ocultas y el aumento de su complejidad.




FIGURA 9.13: TOPOLOGÍA 4_20_20_20_1.

El siguiente paso es determinar las funciones y parámetros para el comienzo del entrenamiento.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

- Numero de capas ocultas: 3 capas ocultas.
- Neuronas en la capa oculta: 20 neuronas.
- Función de activación: Tangente hiperbólica.
- Función de salida: Función identidad.
- Función de aprendizaje: “Backpropagation”

El número de ciclos con los que se entrena cada ratio de aprendizaje, se muestran en la tabla 5. Se recuerda que para el correcto entrenamiento es muy importante que los patrones entren en la red de manera aleatoria, si no la red no estaría aprendiendo de manera correcta.

FACTOR DE APRENDIZAJE (η)	Nº DE CICLOS
0.2	50000
0.1	50000
0.01	50000
0.001	50000

TABLA 5: FACTORES DE APRENDIZAJE PARA 4_20_20_20_1.

En la figura 9.14 puede observarse el error, para los ciclos estimados en la tabla 4.




FIGURA 9.14: GRÁFICO DE ERROR RED 4_20_20_20_1.

Tal y como se muestra el error en la figura 9.14 se observa que durante el entrenamiento con los factores 0.2 y 0.1, la red neuronal se desentrena en ciertos

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

números de ciclos, posteriormente se emplea este gráfico para optimizar el empleo de los ratios de aprendizaje, y entrenar con estos el número de ciclos necesarios.

La figura 9.14 muestra una escala en la que se puede apreciar las curvas para los diferentes ratios pero no se puede apreciar el error con la suficiente exactitud.

Al igual que se realizó en los apartados anteriores, es necesario mostrar una escala mejor, para poder estimar el error de entrenamiento y validación y poder obtener las conclusiones correctas.

En la figura 9.15, se muestra el gráfico de error para 40_20_20_20_1, escalado correctamente.




FIGURA 9.15: GRAFICO DE ERROR 1 RED 4_20_20_20_1.

Como puede verse en el gráfico de error de la figura 9.15, el error cuadrático de entrenamiento da un valor en torno a $6 A^2$. Si comparamos este con el gráfico con el de la figura 9.9 que es la misma red neuronal pero con una capa oculta menos, se puede observar de nuevo que el error de entrenamiento obtenido con tres capas ocultas es menor que el obtenido con 2 capas ocultas.

Antes de comenzar a entrenar con ratios de aprendizaje más pequeños, es aconsejable estimar el número de ciclos donde cada factor de aprendizaje presenta un mínimo, es decir, el último ciclo a partir del cual el error comienza a aumentar con ese mismo factor de aprendizaje.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

Realizando lo comentado anteriormente y observando la figura 9.14, se crea la tabla 6.

FACTOR DE APRENDIZAJE (η)	Nº DE CICLOS
0.2	20000
0.1	5000
0.01	50000
0.001	50000

TABLA 6: FACTORES DE APRENDIZAJE 1 PARA 4_20_20_20_1.

Una vez estimado cuantos ciclos se entrena la red con cada factor de aprendizaje, se obtiene el error de la red en la figura 9.16.




FIGURA 9.16: GRÁFICO DE ERROR 2 RED 4_20_20_20_1.

En la figura 9.16 puede verse la curva de error que presenta la red neuronal durante su entrenamiento con los ratios de aprendizaje 0.2 y 0.1 para pocos ciclos. En conclusión, se puede afirmar que su error (tanto de entrenamiento como de validación) ha disminuido respecto al obtenido en la figura 9.15.

También se puede afirmar que en torno a los 25000 ciclos que es cuando se produce un mayor descenso del error de entrenamiento que es justo cuando se comienza a entrenar con un ratio de aprendizaje de 0.01. Esto significa mucho, ya que sigue manteniendo el mismo modelo de aprendizaje que para las tipologías anteriores, solo que este es más óptimo ya que presenta menor error que los anteriores. Este error en la figura 9.16 no es fácil de apreciar por eso en la figura 9.17, puede verse el error con mayor exactitud.

En la figura 9.17, se muestra el error con una mayor exactitud, ya que es de vital importancia medirlo bien para poder tomar conclusiones y seguir entrenando a la red en

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

el camino adecuado, ya que si el error se estima de manera incorrecta, las soluciones para su disminución también pueden ser incorrectas.




FIGURA 9.17: GRAFICO DE ERROR 3 RED 4_20_20_20_1.

La figura 9.17 nos muestra, que el error, es de aproximadamente $2.5 A^2$, se debe conocer que el error de entrenamiento presenta unas grandes oscilaciones por tanto es difícil cuantificar el error. El método de reducir el número de ciclos de entrenamiento para factores de entrenamiento elevados, parece ser un camino correcto en la reducción del error de la red neuronal.

Se continúa por el mismo camino reduciendo el número de ciclos de entrenamiento para los ratios de aprendizaje 0.2 y 0.1.

Al igual que en el caso anterior se continua manteniendo la misma topología y parámetros, por lo que lo único que se varía es el número de ciclos de entrenamiento con cada factor de aprendizaje.

En la tabla 7 se muestra los datos de entrenamiento a emplear en este caso.

FACTOR DE APRENDIZAJE (η)	Nº DE CICLOS
0.2	3000
0.1	1000
0.01	50000
0.001	50000

TABLA 7: FACTORES DE APRENDIZAJE 2 PARA 4_20_20_20_1.

En la tabla 5 puede verse que se ha reducido todavía más el número de ciclos con los factores 0.2 y 0.1, manteniéndose constantes estos para 0.01 y 0.001.

El gráfico de error para los valores de la tabla 5 se muestra en la figura 9.18.




FIGURA 9.18: GRAFICO DE ERROR 4 RED 4_20_20_20_1.

En la figura 9.18, puede verse como se ha entrenado pocos ciclos con ratios elevados de aprendizaje, y como la curva de error de entrenamiento tarda más tiempo en estabilizarse para un factor de entrenamiento de 0.01, lo que significa, que con este factor se produce una mayor disminución del error.

El error no se puede apreciar con precisión, si se quiere observar el comportamiento al completo de la curva de entrenamiento, tal y como se realizó con los casos anteriores es necesario mostrar otro gráfico (ver figura 9.19) y poder obtener conclusiones.




FIGURA 9.19: GRAFICO DE ERROR 5 RED 4_20_20_20_1

En la figura 9.19, puede observarse un hecho curioso, y es que la figura 9.19 muestra un error superior al de la figura 9.17, por tanto, el seguir reduciendo el número de ciclos de entrenamiento a los elevados ratios de aprendizaje, no ha proporcionado el

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

efecto deseado, por lo que se puede afirmar que este no es un camino correcto en la reducción del error de entrenamiento.

Este hecho ocurre a menudo en el entrenamiento de redes neuronales, ya que no existe una “fórmula” para obtener un error reducido, si no que la prueba-error y la experiencia juegan un papel de vital importancia.

Aunque el resultado reduciendo el número de ciclos para 0.2 y 0.1 no haya sido el deseado, si se puede sacar un aspecto positivo a recalcar, y es que con esta tipología, si se entrena un gran número de ciclos con 0.01 ($\alpha = 0.01$) el error se reduce ya que la curva “tarda” en estabilizarse.

Por tanto, al igual que se hizo con las tipologías anteriores, es decir, con una y dos capas ocultas, comenzaremos entrenando la red con un factor de aprendizaje de 0.01.

La tabla 8 muestra, los números de ciclos y sus diferentes factores.

FACTOR DE APRENDIZAJE (η)	Nº DE CICLOS
0.2	0
0.1	0
0.01	130000
0.001	30000

TABLA 8: FACTORES DE APRENDIZAJE 3 PARA 4_20_20_20_1.

En la figura 9.20, se puede observar la trayectoria que describe la curva de error, para los ciclos indicados en la tabla 5.




FIGURA 9.20: GRAFICO DE ERROR 6 RED 4_20_20_20_1

La figura 9.20 nos muestra que comenzando a entrenar la red con un factor de 0.01, la curva de error de entrenamiento disminuye continuamente y hay que entrenar un gran número de ciclos para que esta se estabilice relativamente. Al igual que en todos

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

los casos anteriores, el factor de 0.001 provoca una disminución del error minúsculo en comparación con 0.01.

A simple vista el error cuadrático se encuentra inferior a $1 A^2$ a los 150000 ciclos. Es necesario realizar una ampliación para poder comparar este con las tipologías anteriores y observar si ha disminuido considerablemente.




FIGURA 9.21: GRAFICO DE ERROR 7 RED 4_20_20_20_1

En primer lugar, se observa en la figura 8.21 que efectivamente el error de entrenamiento está muy reducido, con un valor inferior al de $1 A^2$. Un aspecto muy importante y que hay que mencionar es que la curva rosa que muestra el error de validación está aumentando y superando a la curva de error, que ocurra esto no es buena señal y por lo tanto la red se está sobreentrenando, lo cual puede tener consecuencias negativas y el gráfico de error puede no estar mostrando un error real.

Se debe comparar la figura 9.21 con los errores obtenidos para las tipologías de dos y una capa oculta, que comenzaron entrenando con 0.01 de factor de entrenamiento. Es decir, la figura 9.21 ha de compararse con las figuras 9.12 y 9.7. A continuación se describen las conclusiones obtenidas, que son:

- En primer lugar, el error obtenido en la figura 9.7 es mucho mayor que el obtenido en la 9.21, por lo tanto la topología de una capa oculta queda descartada en la simulación de un modelo inverso de amortiguador MR.
- En segundo lugar, la diferencia entre la figura 9.21 y la 9.12 es muy reducida, siendo ligeramente mayor el error en la figura 9.12 pero la figura 9.21 presenta

un error de validación elevado. Aunque se podría afirmar que ambas tipologías podrían considerarse óptimas el objetivo que nos atañe.

A modo de resumen, sabiendo que el número de neuronas en la entrada y el número de neuronas a la salida permanece constante, lo que se ha realizado para disminuir el error es lo siguiente:

- Se ha variado el número de capas ocultas.
- Se ha variado los ratios de aprendizaje, es decir, no siempre se ha llevado el orden que típicamente se emplea, de mayor a menor factor de aprendizaje.
- Se ha variado el número de ciclos de entrenamiento con cada ratio de aprendizaje.

Ante las tres opciones mencionadas anteriormente, solo cabe una posibilidad más, y es aumentar el número de neuronas en cada capa. Si se volviese a repetir el proceso aumentando el número de neuronas en cada capa, empezando por una capa oculta, siguiendo por dos capas ocultas, y terminando por tres capas ocultas el proceso sería eterno.

Por tanto se debe emplear las conclusiones obtenidas hasta ahora, y a partir de ellas, seleccionar una tipología a la que aumentarle el número de neuronas en la capa oculta. De las conclusiones obtenidas del gráfico de la figura 9.21 quedó descartada la topología de una sola capa oculta, por lo tanto debemos seleccionar o la red de tres capas ocultas y la red de dos capas ocultas.

Ambas tipologías presentaban errores muy parejos cuando comenzaban entrenando con un factor de 0.01 por lo que si se mirara únicamente este aspecto cualquiera de las dos valdría. Sin embargo, en la tipología de dos capas ocultas cuando se comienza entrenando por factores más altos, el error es mayor que en caso de la tipología de tres capas ocultas, es conveniente comparar las figuras 9.17 y 9.10.

Por tanto, la conclusión que se obtiene es que se debe aumentar el número de neuronas a la topología de tres capas ocultas.

9.3.4 RED NEURONAL CON TRES CAPAS OCULTAS Y 30 NEURONAS EN CADA CAPA OCULTA.

En este apartado se aumenta el número de neuronas en cada capa oculta a la red, con el objetivo de observar experimentalmente si esto surge efecto y provoca una disminución del error cuadrático.

En la figura 9.22 puede verse un parte de la tipología de la red, con veinte neuronas en cada capa oculta, a diferencia de las tipologías mostradas en las figuras 9.13 y 9.8, en esta aparece en valor de los pesos de las conexiones y los estados de activación de cada una de las neuronas. Esta tipología ha sido guardada después de un proceso de entrenamiento y el valor de los pesos y los estados de activación quedan guardados. Es necesario y muy importante inicializar estos pesos cuando esta tipología

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

vuelva a ser entrenada con los mismos o con diferentes patrones de entrenamiento, ya que si no se hace, se puede estar cometiendo un error importante durante el entrenamiento, llevando a unas conclusiones erróneas.

El color de las conexiones y de las neuronas es diferente para cada conexión o para cada estado de activación. Si una neurona toma un valor de activación próximo a 1, su color en la red será verde, y sin embargo, si su estado de activación es próximo a -1, su color en la red será rojo. Lo mismo sucede con las conexiones entre las neuronas.




FIGURA 9.22: TOPOLOGÍA 4_30_30_30_1.

Una vez, conocida la forma de la topología y el significado de sus colores en el gráfico, se comienza a entrenar la red.

El resto de los parámetros permanece constante, es decir:

- Numero de capas ocultas: 3 capas ocultas.
- Neuronas en la capa oculta: 30 neuronas.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

- Función de activación: Tangente hiperbólica.
- Función de salida: Función identidad.
- Función de aprendizaje: “Backpropagation”

Para entrenar a la red, de nuevo surge el problema de cuantos ciclos se debe entrenar con cada ratio de aprendizaje. La resolución a este problema la resuelve la experiencia, y los ensayos anteriores, por tanto, al escoger la tipología de tres capas ocultas, se entrenará a la red con el mismo número de ciclos y factores de entrenamiento.

Se entrenará a la red, con los mismos valores de la tabla 6, y la figura 9.17 se comparará con el obtenido para 30 neuronas en cada capa oculta y se sacarán las conclusiones pertinentes.

En la tabla 9 se muestran los ciclos y factores de entrenamiento con los que se entrenó la red 4_30_30_30_1.

FACTOR DE APRENDIZAJE (η)	Nº DE CICLOS
0.2	20000
0.1	5000
0.01	50000
0.001	50000

TABLA 9: FACTORES DE APRENDIZAJE 4_30_30_30_1.

En la figura 9.23 se muestre el error, para los valores de la tabla 6.




FIGURA 9.23: GRÁFICO DE ERROR RED 4_30_30_30_1.

Tal y como nos muestra la figura 9.23, las curvas de error, presentan una tendencia descendente, aspecto muy positivo, ya que el error disminuye, el mayor descenso se sigue produciendo para un ratio de aprendizaje de 0.01. Para el ratio de

aprendizaje 0.001, la curva presenta una disminución casi inapreciable. En resumen, esta curva no tiene nada diferente a las mostradas para veinte neuronas en cada capa oculta. La curva de validación (curva rosa) es menor a medida que se disminuye el ratio de aprendizaje, lo cual ocurría con anterioridad.

No se puede quedar el análisis en un simple resumen de las tendencias de las curvas de error de entrenamiento y validación, es necesario conocer el error cuadrático exacto y comparar este con las topologías anteriores, y tal y como se ha hecho con anterioridad, tomar conclusiones al respecto.

En la figura 9.24, se muestra una ampliación de la curva de error de la figura 9.23.




FIGURA 9.24: GRÁFICO DE ERROR 1 RED 4_30_30_30_1.

El gráfico de la figura 9.24 debe compararse con el de la figura 9.17, ya que esta red (4_30_30_30_1) ha sido entrenada con los mismos ciclos y mismos factores de aprendizaje que la red (4_20_20_20_1). En primer lugar el error de entrenamiento en la figura 9.30 se encuentra entre 3 y 4 A^2 , un poco más cercano a 4, mientras que en la figura 9.17, se encuentra el error cuadrático más próximo a 2 A^2 .

La primera conclusión que podría sacarse a simple vista, es que aumentar el número de neuronas en la capa oculta no se consigue ningún efecto beneficioso en cuanto al error de entrenamiento, y si perjudicial, debido a que la arquitectura de la red es mucho más compleja llevando consigo un mayor tiempo de cálculo de cada una de las salidas de la red.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

El hecho de no obtener un resultado mejorado, no indica que esta topología no sea la correcta, hay que seguir entrenando la red, al igual que se hizo en los apartados anteriores, modificando sus ratios de aprendizaje y su número de ciclos de entrenamiento.

Como el error en la figura 9.24 es superior al de la figura 9.17, se entrena a la red variando el número de ciclos con cada ratio de aprendizaje. Con un solo gráfico de error, no puede estimarse si la red es lo suficientemente óptima, por lo que es necesario realizar ciertas pruebas experimentales.

En la tabla 10 se muestran los factores de aprendizaje para los diferentes ciclos.

FACTOR DE APRENDIZAJE (η)	Nº DE CICLOS
0.2	20000
0.1	1000
0.01	20000
0.001	20000

TABLA 10: FACTORES DE APRENDIZAJE 1 4_30_30_30_1.

En el gráfico de error obtenido por esta tipología para los parámetros mostrados en la tabla 10, puede verse en la figura 9.25.




FIGURA 9.25: GRAFICO DE ERROR 2 RED 4_30_30_30_1.

En la figura 9.25, puede verse la curva que describe el error de entrenamiento, este es muy parecido al obtenido con 20 neuronas en cada capa oculta para la misma topología de red. Puede apreciarse que para factores elevados, la curva presenta

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

desentrenamiento con “crestas” y “valles”, sin embargo para los factores de 0.01 y 0.001, la curva es monótona y presenta menos oscilaciones a medida que se disminuye el factor de aprendizaje.

En la figura 9.26 se muestra una mayor ampliación de este mismo gráfico para poder obtener el error, y sacar las conclusiones pertinentes, es decir, el objetivo es demostrar si compensa o no el aumento de neuronas en la capa oculta.




FIGURA 9.26: GRAFICO DE ERROR 3 RED 4_30_30_30_1.

El error cuadrático mostrado en la figura 9.26, puede observarse que se encuentra en torno a $3 A^2$, si este se compara con la figura 9.17, aunque tenga ratios de aprendizaje diferentes, se aprecia que la figura 9.17 muestra un error un poco más bajo que el de la figura 9.26. En los dos ensayos que se han realizado para 30 neuronas en la capa oculta, los errores han sido superiores a la tipología de 20 neuronas en la capa oculta.

Se llega a la conclusión de que aumentando el número de neuronas en la capa oculta y empezando a entrenar por factores de entrenamiento elevados, el error no se disminuye. Solo queda otra opción para poder afirmar si esta tipología es o no óptima y es empezar entrenando la red por el valor que mejor resultado ha dado, es decir, comenzar entrenando por un ratio de aprendizaje de 0.01, y entrenar con este un gran número de ciclos.

En función del resultado que se obtenga, se podrá afirmar si esta topología de red es válida para el modelo inverso de un amortiguador MR.

Los factores de aprendizaje y el número de ciclos de entrenamiento se muestran en la tabla 11, se han empleado los mismos que en la tabla 8, ya que con esos valores es con los que mejor resultado se obtuvo pero para una tipología 4_20_20_20_1.

FACTOR DE APRENDIZAJE (η)	Nº DE CICLOS
0.2	0
0.1	0
0.01	100000
0.001	17000

TABLA 11: FACTORES DE APRENDIZAJE 2 4_30_30_30_1.

En la figura 9.27, se muestra el gráfico de error para los valores de la tabla 11.




FIGURA 9.27: GRÁFICO DE ERROR 4 RED 4_30_30_30_1.

Como puede verse en la figura 9.27, el error describe una curva asintótica hacia cero. Durante el entrenamiento con el ratio de aprendizaje de 0.01, el descenso se hace muy pronunciado durante los primeros ciclos, y este se va estabilizando en torno a los 100000 ciclos, justo el momento en el que se debe cambiar de factor de aprendizaje.

A diferencia de otros casos anteriores cuando se sigue entrenando a la red con un factor de aprendizaje de 0.01, el error sigue disminuyendo, hecho que con anterioridad no pasaba. Si es cierto, que la curva de error de validación aumenta superando al error de entrenamiento, hecho que debe tenerse en cuenta para tomar decisiones.

Una vez observado a simple vista, que sucede en la curva del error cuadrático, es necesario observar el error en otra toma más ampliada. Se necesita conocer su valor con exactitud y compararlo con la tipología de mismas capas ocultas pero con 20 neuronas en cada capa oculta.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

En la figura 9.28 se muestra el gráfico de error ampliado, y se observa que el error cuadrático de entrenamiento ha disminuido por debajo de $1 A^2$. En la figura 9.28 se aprecia que los errores de entrenamiento y de validación muestran unas grandes oscilaciones y por tanto es difícil estimar con una gran precisión el error cometido.

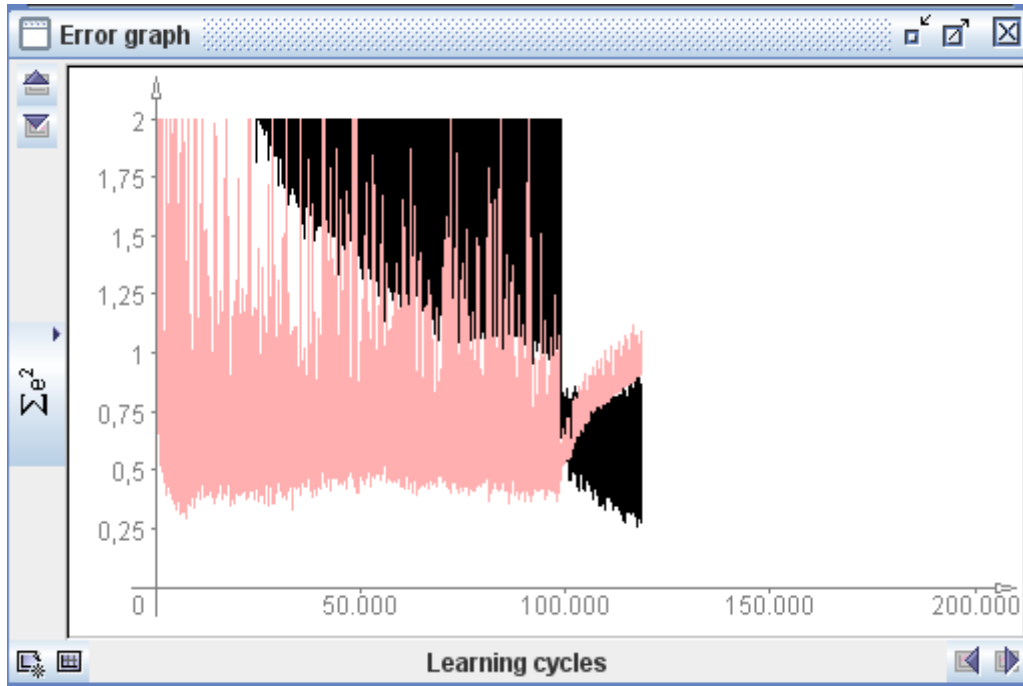


FIGURA 9.28: GRÁFICO DE ERROR 5 RED 4_30_30_30_1.

9.4 VALIDACIÓN.

Las tipologías de red que menores errores de entrenamiento y validación han presentado son 4_20_20_20_1 y 4_30_30_30_1, siendo el error un poco mayor en la segunda. Para validar el sistema y poder elegir la tipología de red para el modelo inverso de amortiguador MR, es necesario conocer los errores de entrenamiento y de validación con una mayor exactitud.

En el programa empleado para el entrenamiento de la red neuronal, existe una ventana (LOG), la cual aporta el error de entrenamiento y de validación numéricamente.

Debe de mostrarse los errores de entrenamiento y de validación de las dos tipologías y posteriormente tomar conclusiones pertinentes para seleccionar la tipología más óptima para nuestro modelo

En la figura 9.29 se muestra los errores de entrenamiento y de validación para 4_30_30_30_1.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

Step	SSE	validation
Step 13000	3.908668491363525	0.895203590393066
Step 26000	2.7538793087005615	0.455615639686584
Step 39000	2.7513177394866943	0.621423900127410
Step 52000	1.5245819091796875	0.560363233089447
Step 65000	1.4623137712478638	0.516636252403259
Step 78000	1.6972087621688843	0.528710126876831
Step 91000	1.2848793268203735	2.420622587203979
Step 99000	0.685870885848999	0.546292185783386
Step 102000	0.7627204060554504	0.600358128547668
Step 105000	0.6724366545677185	0.729682803153991
Step 108000	0.6417065262794495	0.820621907711029
Step 111000	0.622747004032135	0.830159008502960
Step 114000	0.6519843935966492	0.865703284740448
Step 117000	0.5708557367324829	1.02747642993927

FIGURA 9:29: ERRORES NUMÉRICOS DE ENTRENAMIENTO Y VALIDACIÓN 4_30_30_30_1.

Tal y como se muestra en la figura 9.29 los últimos valores de entrenamiento y validación se obtienen a 117000 ciclos debido a que el error de validación aumentaba superando la unidad.

Los errores de entrenamiento y validación en los que debemos fijarnos, son los últimos aportados por la red. En la tabla 12 se muestran dichos errores.

Número de ciclos	Error de entrenamiento SSE (A^2)	Error de validación (A^2)
72000	0.5708557	1.0274764

TABLA 12: ERRORES DE ENTRENAMIENTO Y VALIDACIÓN 4_30_30_30_1.

En segundo lugar debe obtenerse los errores de validación y entrenamiento para la tipología de red 4_20_20_20_1 y compararlos con los errores de la tabla 12.

En la figura 9.30, se observan los errores de numéricos de entrenamiento y validación para la tipología 4_20_20_20_1.

Se observa una gran cantidad de valores tanto de error de entrenamiento (SSE) como de validación (“validation”) al igual que en el caso anterior debe de obtenerse el último valor del entrenamiento.

Tal y como se muestra en la figura 9.30 el error de validación es superior al error de entrenamiento, por lo que en primer lugar debemos comparar los valores con los obtenidos en la red 4_30_30_30_1 y una vez comparados y discutidos, elegir la red óptima para el modelo inverso.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

Log			
Step 108000 SSE:	1.3728018999099731	validation:	0.5094101428985596
Step 111000 SSE:	1.5602816343307495	validation:	1.07982337474823
Step 114000 SSE:	1.570296287536621	validation:	0.4517825245857239
Step 117000 SSE:	1.0161935091018677	validation:	0.46356436610221863
Step 120000 SSE:	1.4037307500839233	validation:	0.5646882653236389
Step 123000 SSE:	1.1548210382461548	validation:	0.35740604996681213
Step 126000 SSE:	1.2551822662353516	validation:	0.38487982749938965
Step 129000 SSE:	0.5929030776023865	validation:	0.43114280700683594
Step 132000 SSE:	0.4637993574142456	validation:	0.4707944691181183
Step 135000 SSE:	0.45679181814193726	validation:	0.5022494792938232
Step 138000 SSE:	0.4079788327217102	validation:	0.5266141891479492
Step 141000 SSE:	0.4442252218723297	validation:	0.5680205821990967
Step 144000 SSE:	0.47753018140792847	validation:	0.6133215427398682
Step 147000 SSE:	0.40269535779953003	validation:	0.667806088924408
Step 150000 SSE:	0.3401045799255371	validation:	0.6856281161308289
Step 153000 SSE:	0.3618091940879822	validation:	0.668440580368042
Step 156000 SSE:	0.20470845699310303	validation:	0.6879796981811523

FIGURA 9.30: ERRORES DE ENTRENAMIENTO Y VALIDACIÓN PARA 4_20_20_20_1.

En la tabla 13 se muestran los errores de validación y entrenamiento para la tipología 4_20_20_20_1.

Número de ciclos	Error de entrenamiento SSE (A^2)	Error de validación (A^2)
156000	0.20470845	0.68797969

TABLA 13 : ERRORES DE ENTRENAMIENTO Y VALIDACIÓN PARA 4_20_20_20_1

Al comparar las tablas 12 y 13 se observa que el error de entrenamiento y validación es menor para una tipología de red 4_20_20_20_1, por lo que esta red, entrenada el número de ciclos y ratios de aprendizaje indicados, es la seleccionada para el modelo inverso de amortiguador MR.

Una vez seleccionada la tipología que mejor resultados ha proporcionado es necesario, y ya como último paso, obtener las salidas que nos proporciona la red (intensidad de corriente), y comparar mediante un gráfico las corrientes deseadas.

En primer lugar se obtienen los resultados en un archivo de texto. Estos posteriormente son traspasados a un programa para generar gráficas comparativas, donde es necesario eliminar las filas pares, que representan el número del patrón de aprendizaje, y posteriormente, hacer un gráfico con las salidas deseadas que formaban parte del conjunto de datos del patrón de aprendizaje.

Se realiza un gráfico de dispersión, con el fin de observar si los datos generados por la red neuronal son suficientemente reales, y se aproximan a los deseados.

MODELO INVERSO DE AMORTIGUADOR MR BASADO EN REDES NEURONALES

La figura 9.31 muestra el grafico entre la salida deseada y la estimada por la red 4_20_20_20_1 después de ser entrenada. Como las salidas generadas por la red no dan valores exactos la curva azul muestra determinadas oscilaciones pero podría afirmarse que el valor medio de estas es muy parecido a las salidas deseadas (curva roja). Debe de recordarse que las intensidades deseadas iban de 0.2 hasta 0.8 Amperios. Es importante definir las unidades, ya que el error es cuadrático pero las salidas generadas por la red son en Amperios.




FIGURA 9.31: INTENSIDAD DESEADA FRENTE INTENSIDAD DE LA RED NEURONAL.

CAPÍTULO 10: CONCLUSIONES Y TRABAJOS FUTUROS

10.1 CONCLUSIONES

El principal objetivo de este Trabajo de Fin de Grado es analizar y estudiar un modelo inverso de amortiguador MR mediante redes neuronales. Como ya se ha dicho, en estudios anteriores se ha demostrado que las redes neuronales sí consiguen buenos resultados para los modelos directos, pero con los inversos cuyo principal objetivo es establecer la relación, entre la fuerza, desplazamiento, velocidad y frecuencia frente a la intensidad de corriente, su resultado era considerablemente peor.

Para los modelos no paramétricos directos el empleo de una única capa oculta, y entrenar una serie de ciclos no muy elevada, e ir variando el factor de aprendizaje desde 0.2 hasta 0.001 era suficiente para obtener un error cuadrático medio muy reducido. Sin embargo, no ocurre lo mismo para el caso de un modelo inverso. En el capítulo 9 se ha ido probando experimentalmente con una, con dos, con tres capas ocultas, se ha variado el factor de aprendizaje, elemento fundamental para alcanza el error mínimo, y también se ha variado el número neuronas en cada capa oculta sin obtener resultados tan buenos como para los obtenidos con el modelo directo. Sin embargo, se han obtenido errores de entrenamiento y validación en torno a 0.2 y 0.6 A^2 respectivamente, los cuales son bastante aceptables, y si además se observa el gráfico 9.31, se puede afirmar que las redes neuronales multicapa son óptimas para un modelo inverso.

Una vez conocido esto puede obtener la conclusión, de que una tipología con tres capas ocultas, y veinte neuronas en cada capa oculta genera una solución óptima. También, es necesario reseñar que la misma tipología pero con treinta neuronas en cada capa oculta, proporcionaba un error cuadrático reducido, pero atendiendo a la figura 8.30 se ha estimado que la red 4_20_20_20_1 entrenada es la red empleada en el modelo inverso. Para conseguir el resultado y entrenar correctamente a la red, debe seguirse los pasos establecidos en la tabla 11.

Por tanto la red 4_20_20_20_1 entrenada es la seleccionada para el modelo inverso de amortiguador MR en una suspensión semi-activa. Esta red debe ser capaz de generar la corriente deseada en el amortiguador para ejercer la fuerza indicada por el controlador. Por tanto, con la red neuronal entrenada, estamos controlando en todo

momento el esfuerzo viscoso en el amortiguador, y por tanto, la estabilidad de la suspensión del vehículo en concreto.

En conclusión, las redes neuronales multicapa son una buena herramienta, ante la relación no lineal entre fuerza, frecuencia, desplazamiento y velocidad frente a la intensidad con la que se debe alimentar el amortiguador MR.

10.2 TRABAJOS FUTUROS

En un amortiguador MR influyen numerosos factores como la intensidad del campo, el campo magnético generado por este, si es suficiente o no, como se encuentran las partículas en suspensión, su tamaño, su forma. También un factor muy importante es la temperatura, ya que a elevadas temperaturas la magnetización cambia y por tanto la alineación de las partículas puede ser deficiente. Por tanto en trabajos futuros deben tenerse en cuenta todos estos factores para conseguir un modelo inverso más óptimo de amortiguador MR, ya que en este trabajo se ha tenido en cuenta la fuerza, el desplazamiento, la frecuencia y la velocidad, por lo que el incluir más parámetros supondría una mayor complejidad pero también unos mejores resultados de cara a una futura implantación en una suspensión vehicular

BIBLIOGRAFÍA

- [1] Componentes de la suspensión vehicular.
<http://www.aficionadosalamecanica.net/suspension2.htm>
- [2] Varios Autores, “Mecánica del Automóvil”, colección GTZ.
- [3] H.E. Jorge, M. Anthony, G.C. Alfonso, Los sistemas de suspensión activa y semiactiva: Revisión.
- [4] An Introduction to Active Suspension Systems.
http://www-control.eng.cam.ac.uk/gww/what_is_active.html
- [5] J. Rabinow, Magnetorheological fluids, at US National Bureau of Estandars, 1940.
- [6] C.R. Miguel, E.G. Fernando, Amortiguadores magnetoreológicos.
- [7] P. Tipler, G. Mosca, Física para la Ciencia y la Tecnología.
- [8] Ehergott R C and Masri S F 1992 Modeling the oscillatory dynamic behavior of electrorheological materials.
- [9] Gavin H P, Hanson R D and Filisko F E 1996 Electrorheological dampers.
- [10] Schurter K C and Roschke P N 2000 Fuzzy modeling of a magnetorheological damper using Anfis.
- [11] Wilson C M D and Abdullah M 2005 Structural vibration reduction using fuzzy control of magnetorheological dampers.
- [12] Stanway R, Sproston J L and Stevens N G 1987 Non-linear modeling of an electrorheological vibration damper.
- [13] Spencer B F, Dyke S J, Sain M K and Carlson J D 1997 Phenomenological model of a magnetorheological damper.
- [14] Gamota D R and Filisko F E 1991 Dynamic mechanical studies of electrorheological materials: moderate frequencies.
- [15] Wereley N M, Pang L and Kamath G M 1998 Idealized hysteresis modeling of electrorheological and magnetorheological dampers.
- [16] Choi S B, Lee S K and Park Y P 2001 A hysteresis model for the field-dependent damping force of a magnetorheological.

- [17] Sahin, T.Engin, S.Sesmecı 2010 Comparison of some existing parametric models for magnetorheological fluid dampers.
- [18] Zhou Q, Nielsena S R K and Qu W L 2006 Semi-active control of three-dimensional vibrations of an inclined sag cable with magnetorheological dampers.
- [19] Dahl P R 1976 Solid friction damping of mechanical vibrations.
- [20] Kwok N M, Ha Q P, Nguyen T H, Li J and Samali B 2006 A novel hysteretic model for magnetorheological fluid dampers and parameter identification using particle swarm.
- [21] Guo D and Hu H 2005 Nonlinear-stiffness of a magnetorheological fluid d mper.
- [22] L.K. Hansen, M.W. Pedersen, Controlled growth of cascade correlation nets.
- [23] R.A. Jacobs, Increased rates of convergence through learning rate adaptation, Neural Networks.
- [24] R. Fletcher, Practical Methods of Optimization, Wiley, New York, 1987.
- [25] P.Q. Xia An inverse model of MR damper using optimal neural network and system identification.
- [26] Castillo E. y Cobo A. Introducci n a la redes funcionales con aplicaciones: un nuevo paradigma neuronal, Paraninfo 1999.
- [27] M. Villasana, Introducci n a las Redes Neuronales Artificiales.
- [28] Caracter sticas de las redes neuronales.
- <http://thales.cica.es/rd/Recursos/rd98/TecInfo/07/capitulo3.html>
- [29] M. Valencia, C. Y  ez, L.P. S  nchez, Algoritmo Backpropagation para Redes Neuronales: Conceptos y Aplicaciones.
- [30] Regla de aprendizaje: Backpropagation.
- <http://proton.ucting.udg.mx/posgrado/cursos/idc/neuronales2/ReglaB.htm>